

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Petra Gržinić

Zagreb, 2019.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Prof. dr.sc. Zoran Kunica

Studentica:

Petra Gržinić

Zagreb, 2019.

ZADATAK**SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE**

Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske radove studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment,
inženjerstvo materijala te mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa:	
Ur. broj:	

DIPLOMSKI ZADATAK

Student: **PETRA GRŽINIĆ** Mat. br.: 0069065510

Naslov rada na hrvatskom jeziku: **Indeks ekonomske složenosti i proizvodnja u Republici Hrvatskoj**

Naslov rada na engleskom jeziku: **Index of economic complexity and production in the Republic of Croatia**

Opis zadatka:

Indeks ekonomske složenosti je holistička mjera proizvodnih sposobnosti velikih ekonomskih sustava, poput gradova, regija ili zemalja. Indeks ekonomske složenosti nastoji obuhvatiti mjeru ukupnog proizvodnog znanja akumuliranog unutar neke populacije, a na temelju njenih gospodarstvenih aktivnosti, pri čemu on nije samo deskriptivna, već i prediktivna mjera gospodarstvenog rasta.

U radu je potrebno:

1. Izučiti indeks ekonomske složenosti.
2. Opisati položaj Republike Hrvatske prema metrici indeksa ekonomske složenosti.
3. Identificirati proizvode Republike Hrvatske s obzirom na njihovu važnost u globalnoj podjeli rada danu indeksom ekonomske složenosti.
4. Za proizvode iz točke 3., istražiti u kojim se i kakvim proizvodnim sustavima realiziraju, sukladno dostupnosti podataka (kao što su, naprimjer: količine, tehnologije i strukture, lokacije, vlasništvo).
5. Preporučiti mjere za povećanje indeksa ekonomske složenosti Republike Hrvatske.
6. Razmotriti mogućnost korištenja indeksa ekonomske složenosti u projektiranju proizvodnih sustava, s obzirom na vrstu i opseg potrebnih podataka te primjenu potencijalnih metoda.

Zadatak zadan:
02. svibnja 2019.

Zadatak zadao:

prof. dr. sc. Zoran Kunica

Rok predaje rada:
04. srpnja 2019.

Predviđeni datum obrane:
10. srpnja 2019.
11. srpnja 2019.
12. srpnja 2019.

Predsjednica Povjerenstva:

prof. dr. sc. Biserka Runje

IZJAVA

Izjavljujem da sam ovaj rad izradila samostalno, koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem mentoru prof. dr. sc. Zoranu Kunici i asistentu Damiru Beliću, mag. ing. na pomoći oko izrade ovog rada.

Petra Gržinić

U Zagrebu 4. srpnja 2019.

SADRŽAJ

ZADATAK.....	I
IZJAVA.....	II
POPIS OZNAKA	V
POPIS SLIKA	VI
POPIS TABLICA.....	VII
SAŽETAK.....	VIII
SUMMARY	IX
1. UVOD	1
2. GOSPODARSTVO REPUBLIKE HRVATSKE	3
2.1. Republika Hrvatska unutar Europske unije.....	3
2.2. Makroekonomski pokazatelji gospodarstva	4
2.3. <i>Europa 2020.</i> i strategija gospodarstvenog razvoja.....	8
2.4. Izvoz RH s obzirom na indeks ekonomske složenosti	10
3. INDEKS EKONOMSKE SLOŽENOSTI	13
3.1. Mjerenje indeksa ekonomske složenosti.....	16
3.2. Atlas ekonomske složenosti.....	18
3.3. Prostor proizvoda	19
3.4. Indeks složenosti proizvoda	23
3.5. Najsloženiji i najjednostavniji svjetski i hrvatski proizvodi prema indeksu složenosti proizvoda u 2017. godini	24
4. ATLAS EKONOMSKE SLOŽENOSTI REPUBLIKE HRVATSKE	27
4.1. Prostor proizvoda hrvatskog gospodarstva u 2016. godini.....	27
4.1.1. Poljoprivredni proizvodi	29
4.1.2. Kemikalije.....	30
4.1.3. Strojevi.....	31
4.1.4. Tekstili	32
4.2. Najsloženiji proizvodi u 2016. godini s obzirom na njihovu globalnu raspodjelu (RCA) i indeks složenosti proizvoda (PCI)	33
4.3. Proizvodnja hrvatskih najsluženijih proizvoda	36
4.3.1. RADIN-GRAFIKA d.o.o.....	37

4.3.2. P.P.C. Buzet d.o.o. i SAS Strojogradnja d.o.o.	38
5. MJERE POVEĆANJA INDEKSA EKONOMSKE SLOŽENOSTI RH.....	40
6. MOGUĆNOST PRIMJENE INDEKSA EKONOMSKE SLOŽENOSTI ZA PROJEKTIRANJE PROIZVODNIH SUSTAVA.....	45
6.1. Hipoteza	45
6.2. Model	46
6.3. Proširenje osnovnog modela primjenom indeksa složenosti	48
6.3.1. Preporučene tehnologije za razvoj i primjenu proširenog modela.....	50
7. ZAKLJUČAK.....	52
8. LITERATURA	54

POPIS OZNAKA

BDP	bruto domaći proizvod
BND	bruto nacionalni proizvod
COMTRADE	Baza podataka Statističkog odjela Ujedinjenih Naroda
DZS	Državni zavod za statistiku
ECI	indeks ekonomske složenosti (engl. <i>Economic Complexity Index</i>)
EK	Europska komisija
engl.	engleski
EU	Europska unija
EUROSTAT	Statistički ured Europskih zajednica
FDI	izravna strana ulaganja
HNB	Hrvatska narodna banka
HRK	hrvatska kuna
HS	harmonizirani sustav
ILO	Međunarodna organizacija rada
<i>k</i>	koeficijent
MMF	Međunarodni monetarni fond
njem.	njemački
OECD	Organizacija za ekonomsku suradnju i razvoj
P	proizvod
PCI	indeks složenosti proizvoda
PISA	Program za međunarodnu procjenu studenata
RCA	indeks iskazane komparativne prednosti
RH	Republika Hrvatska
S	proizvodni sustav
SMTK	Standardna međunarodna trgovinska klasifikacija
UN	Ujedinjeni narodi
USD	američki dolar
WGI	Svjetski pokazatelji upravljanja
α	vrijednost indeksa složenosti proizvoda (PCI)

POPIS SLIKA

Slika 1. Reprezentativan primjer hrvatskog novca – banski denar (banovac), koji su kovali nasljednici hercega Andrije od 1235. do 1384. u Zagrebu i Pakracu. [1]	1
Slika 2. Strategije Republike Hrvatske s obzirom na referentni okvir <i>Europe 2020</i> . [12]	9
Slika 3. Geografska karta zemalja s obzirom na indeks ekonomske složenosti njihovih gospodarstava iz 2016. [22]	18
Slika 4. Prostor proizvoda s pripadajućim simbolima koji predstavljaju različite skupine proizvoda [19]	21
Slika 5. Prostor proizvoda gospodarstva Nigerije s obzirom na izvoz u 2016. [23]	22
Slika 6. Prostor proizvoda japanskog gospodarstva s obzirom na izvoz u 2016. [23]	22
Slika 7. Prostor proizvoda hrvatskog gospodarstva s obzirom na izvoz u 2016. [15]	28
Slika 8. Prostor poljoprivrednih proizvoda hrvatskog gospodarstva u 2016. godini [15]	29
Slika 9. Prostor proizvoda kemikalija u hrvatskom gospodarstvu u 2016. [15]	30
Slika 10. Prostor proizvoda strojeva u hrvatskom gospodarstvu u 2016. [15]	31
Slika 11. Prostor tekstilnih proizvoda u hrvatskom gospodarstvu u 2016. [15]	32
Slika 12. Zemlje u koje tvrtka RADIN-GRAFIKA d.o.o. izvozi svoje proizvode [26]	37
Slika 13. Zemlje u koje tvrtka SAS Strojogradnja d.o.o. izvozi svoje proizvode [26]	39
Slika 14. Grafikon izvodljivosti za gospodarstvo RH u 2016. [15]	40
Slika 15. Grafikon izvodljivosti za proizvodnu skupinu <i>strojevi</i> prema prostoru proizvoda RH u 2016. [15]	41
Slika 16. Grafikon izvodljivosti za proizvodnu skupinu <i>kemikalije</i> prema prostoru proizvoda RH u 2016. [15]	42
Slika 17. Grafikon izvodljivosti za proizvodnu skupinu <i>vozila</i> prema prostoru proizvoda RH u 2016. [15]	42
Slika 18. Grafikon izvodljivosti za proizvodnu skupinu <i>elektronika</i> prema prostoru proizvoda RH u 2016. [15]	43
Slika 19. Mreža proizvodnih sustava (S) i proizvoda (P)	46

POPIS TABLICA

Tablica 1. Makroekonomski rezultati hrvatskoga gospodarstva u tranziciji u razdoblju od 1989. do 2001. [7]	5
Tablica 2. Makroekonomski pokazatelji hrvatskog gospodarstva 2016. i 2017. [8]	6
Tablica 3. Proizvodi koje najviše izvozi RH prema rangu ekonomske složenosti.....	11
Tablica 4. Pokazatelji upravljanja Svjetske banke (WGI) za Hrvatsku [20]	15
Tablica 5. Najsloženiji proizvodi prema indeksu složenosti proizvoda u 2017. godini [23]..	25
Tablica 6. Najjednostavniji proizvodi prema indeksu složenosti proizvoda u 2017. godini [23]	26
Tablica 7. Najsloženiji proizvodi u izvozu RH u 2016. [15 i 29]	33
Tablica 8. Proizvodi najpogodniji za diverzifikaciju i ubrzanje rasta hrvatskog gospodarstva – Što je potrebno proizvoditi? [15]	44

SAŽETAK

U ovom se radu pomoću holističkih mjera gospodarstvenog rasta makroekonomskih sustava – indeksa ekonomske složenosti i indeksa složenosti proizvoda, nastoji analizom i sintezom trgovinskih podataka iz relevantnih svjetskih baza podataka opisati i predvidjeti proizvodnja kao aspekt gospodarstvenog rasta u Republici Hrvatskoj. Rad odgovara na neka od temeljnih pitanja proizvodnje suvremenog doba izraženog brzorastućom kompleksnošću, dinamičnošću i neizvjesnošću: *što i kako proizvodimo* te *što je potrebno proizvoditi*? Ustanovljeno je da se posebno ističu sljedeće skupine proizvoda: strojevi, kemikalije, vozila i elektronika. Također, razvijen je i opisan model primjene indeksa ekonomske složenosti na projektiranje proizvodnih sustava, a na osnovi metode refleksije.

KLJUČNE RIJEČI: indeks ekonomske složenosti (ECI), Atlas ekonomske složenosti, indeks složenosti proizvoda (PCI), proizvodnja, proizvodni sustav

SUMMARY

This thesis analyses the production as an aspect of economic growth in the Republic of Croatia using the holistic measures of the productive capabilities of large economic systems: the Economic Complexity Index (ECI) and the Product Complexity Index. The thesis answers to some of the fundamental questions of contemporary production in the Republic of Croatia which is characterized by fast-growing complexity, dynamism and uncertainty: *what do we produce* and *what needs to be produced*? The following important product groups have been identified: machinery, chemicals, vehicles and electronics. Also, the model of the application of the ECI to the design of production systems has been developed and described using the method of reflection.

KEYWORDS: Economic Complexity Index (ECI), Atlas of Economic Complexity, Product Complexity Index (PCI), Production, Production System

1. UVOD

Tijekom povijesti, začeci strojarske struke u Hrvatskoj sazrijevali su unutar kovačkih (Slika 1.), ljevarskih, kolarskih i drugih obrta čiji su majstori obrtnici svoja umijeća temeljili na usmenoj predaji, odnosno iskustvu. Strojarska struka je prirodno usko isprepletena s različitim gospodarstvenim djelatnostima koje sadržajem i podjelom rada, razmjenom, organizacijom proizvodnje i upravljanjem čine temelj čovjekova života u suvremenoj zajednici. Strojarska je struka, kao i ostale grane gospodarstva, usmjerena na *olakšavanje* ili zamjenu *ljudskog rada* strojevima, robotima, umjetnom inteligencijom i drugim, te mora odgovoriti na neka od temeljnih pitanja: *što je potrebno proizvoditi? Kako i koliko proizvoditi? Kada započeti proizvodnju?* Pitanje svrhe olakšavanja ili zamjene ljudskog rada danas je nerijetko domena prijepora znanstveno, politički i gospodarstveno oprečnih misli. Paleta suvremenih i složenih problema odnosa čovjeka spram svoje zajednice i okoliša u kojem živi svodi se na pretjerano pojednostavnjeni nazivnik *eksploatacije zbog* (često – pojedinčeve, ili vlastite) *dobiti*.



Slika 1. Reprezentativan primjer hrvatskog novca – banski denar (banovac), koji su kovali nasljednici hercega Andrije od 1235. do 1384. u Zagrebu i Pakracu. [1]

Odnos i svrhe strojarske struke i gospodarstva ne mogu se u potpunosti svesti na rješavanje svega nekoliko jednostavnih pitanja, a suvremeno doba karakterizirano izraženom brzorastućom kompleksnošću, dinamičnošću i neizvjesnošću, kako u svijetu, tako i u Hrvatskoj, svakodnevno zahtijeva neposredne i jednoznačne, a nerijetko i brze odgovore na upravo ta *jednostavna* pitanja. Na ta pitanja ovdje će se pokušati odgovoriti proučavajući svrsishodnost rada koji su 2009. godine objavili César A. Hidalgo i Ricardo Hausmann a

kojim se formulira holistička mjera proizvodnih sposobnosti velikih ekonomskih ili makroekonomskih sustava poput gradova, regija ili zemalja – takozvani *indeks ekonomske složenosti* (engl. *Economic Complexity Index*). Indeks ekonomske složenosti, uz indeks složenosti proizvoda (engl. *Product Complexity Index*), temelj su skupine alatā objedinjenih unutar *Atlase ekonomske složenosti* za opis (deskripciju) i predviđanje (predikciju) trgovinskih podataka, odnosno gospodarstvenog rasta i složenosti pojedinih makroekonomskih sustava.

Dakle, cilj je ovog diplomskog rada bio pomoću tih alatā odgovoriti na jednostavna pitanja kako sadašnje, tako i buduće proizvodnje u Republici Hrvatskoj: *što proizvodimo? Što je potrebno proizvoditi? Kako i koliko proizvoditi?*

Rad je podijeljen u šest poglavlja. U prvom poglavlju opisuje se sadašnje hrvatsko gospodarstvo. Drugo poglavlje izučava indeks ekonomske složenosti (ECI) i s njim povezane mjere poput indeksa složenosti proizvoda (PCI). U trećem poglavlju, s obzirom na njihovu važnost kako za (budući) gospodarstveni rast tako i na globalnom tržištu rada, identificiraju se proizvodi u takozvanom *prostoru proizvoda* hrvatskog gospodarstva. U četvrtom se poglavlju istražuje u kojim se i kakvim proizvodnim sustavima realiziraju ti proizvodi. Konačno, peto i šesto poglavlje sadrže preporučene mjere za povećanje indeksa ekonomske složenosti hrvatskog gospodarstva i model primjene indeksa ekonomske složenosti u projektiranju proizvodnih sustava.

2. GOSPODARSTVO REPUBLIKE HRVATSKE

2.1. Republika Hrvatska unutar Europske unije

Hrvatska je tijekom čitave svoje povijesti imala složen geopolitički položaj, što je bila posljedica promjena u geografskom shvaćanju *regije*, ali i promjena u društveno-političkim odnosima. Tako je Hrvatska bila različito karakterizirana kao južnoeuropska, istočnoeuropska, srednjoeuropska, jugoistočna ili pak mediteransko-podunavska zemlja. [2]

U širem okruženju područja koje se danas određuje kao hrvatski teritorij, tijekom povijesti su sazrijevala i politički i gospodarstveno, a i civilizacijski moćna središta: starogrčko, rimsko, bizantsko, franačko, ugarsko, osmansko i venecijansko. Njihovi su se utjecaji prožimali, a nerijetko i sukobljavali, ostavljajući tragove u raznovrsnom hrvatskom materijalnom i duhovnom naslijeđu. Izravna posljedica pripadnosti različitim regijama i političkim središtima tijekom povijesti bila je dugotrajna razjedinjenost hrvatskih zemalja. [2]

Republika Hrvatska (RH) postala je 1. srpnja 2013. godine 28. punopravna članica Europske unije (EU) – jedinstvene ekonomske i političke unije država europskog kontinenta. Time je prihvatila Pravnu stečevinu Europske unije (EU), odnosno zakonodavstvo koje obvezuje sve članice EU, a sastoji se od 35 poglavlja. Poglavlje 18. (Statistika) obuhvaća metodologiju, klasifikaciju i procedure u prikupljanju podataka iz različitih područja, kao što su statistička infrastruktura, makroekonomska statistika, statistika cijena, poslovna statistika, socijalna politika, poljoprivredna statistika i tako dalje. [3]

Shodno Pravnoj stečevini, gospodarstveni se položaj RH unutar EU najčešće pojednostavnjeno razmatra prema najčešćem kvantitativnom pokazatelju razvojne ekonomije – bruto domaćem proizvodu (BDP). BDP se još klasificira i kao makroekonomski pokazatelj gospodarstvenog razvoja zemalja u metodologiji razvojne geografije i ekonomske geografije. Prema posljednjem izvješću Europske komisije (EK) iz svibnja 2018., a za prethodnu 2017. godinu, hrvatsko gospodarstvo spada u skupinu 11 zemalja članica čija gospodarstva (redosljedom od najvećeg prema najmanjem: mađarsko, slovačko, luksemburško, bugarsko,

hrvatsko, slovensko, litvansko, latvijsko, estonsko, ciparsko i malteško) imaju BDP manji od 1 % BDP-a Europske unije. [4]

2.2. Makroekonomski pokazatelji gospodarstva

Pod pojmom *hrvatsko gospodarstvo* u ovom se diplomskom radu razumijeva gospodarstvo Republike Hrvatske **nakon stjecanja** nezavisnosti Domovinskim ratom. Hrvatsko se gospodarstvo u tom procesu nastojalo upraviti prijelazu (tranziciji) iz tržišno usmjerenog socijalističkog samoupravljanja, odnosno sustava temeljenog na društvenom vlasništvu i društvenom samoupravljanju, u sustav temeljen na privatnom vlasništvu i tržišnoj ekonomiji. Prijelaz je (bio) otežan različitim ratnim i poratnim zaprjekama. [5 i 6]

Jedna od njih je izravna ratna šteta procijenjena na 236 milijardi kuna (HRK), odnosno izravna ratna šteta na samo **gospodarstvo** u razdoblju od 1990. do 1999. procijenjena na 36 milijardi HRK. Razmatrajući izravnu ratnu štetu na gospodarstvo, uočljivo je da niti jedna zemlja članica EU, od 1990. do danas, nije sudjelovala u ratnom sukobu tih (gospodarstvenih) razmjera. Stoga valja s posebnim oprezom tumačiti raznovrsne i brojne statističke usporedbe s ostalim članicama EU. [6 i 7]

U tumačenju prijelaza (tranzicije) u sustav temeljen na privatnom vlasništvu i tržišnoj ekonomiji, pojmovi pretvorbe i privatizacije često se koriste kao sinonimi. No, *pretvorba* je vezana uz promjenu pravnog statusa društvenih poduzeća u trgovačka društva, a *privatizacija* je proces transformacije državnog u privatno vlasništvo, odnosno prodaja državnih poduzeća privatnim pravnim i fizičkim osobama. RH je u ovom procesu naišla na dodatne zaprjeke. [7]

Istraživanjem dostupne znanstvene literature pronađeni su izvori koji djelomično opisuju pozitivne i negativne zaprjeke pretvorbe i privatizacije prema kojima su makroekonomski rezultati tranzicije proturječni i mogu se vrjednovati u širokoj skali od veoma dobrih do veoma loših kako je opisano u tablici 1. [7]

Tablica 1. Makroekonomski rezultati hrvatskoga gospodarstva u tranziciji u razdoblju od 1989. do 2001. [7]

<i>Makroekonomski rezultati hrvatskoga gospodarstva u tranziciji</i>	
veoma dobri	veoma loši
Ostvareni stupanj stabilnosti gospodarstvenih kretanja.	Niska razina razvitka (mjereno razinom BDP-a oko 70 %) u odnosu na predtranzicijsku i predratnu 1989. godinu.
Nominiranje vlasnika.	Niska stopa rasta BDP-a.
Izravna asignacija formalno-pravne odgovornosti.	Visoke stope nezaposlenosti koje se povećavaju i niska iskorištenost postojećih proizvodnih kapaciteta.
Izravna asignacija gospodarstvenoga rizika.	Veliko međusobno zaduživanje s posljedicom povećavanja problema likvidnosti.
Formiranje tržišnog makroekonomskog sustava.	Neuravnoteženi odnosi cijena domaćeg i stranog novca.
Normativno usklađenje s europskim standardima i međunarodna usporedivost.	Niska razina kako domaćih tako i stranih investicija.
	Bolji uvjeti poslovanja za uvoznike spram izvoznika.
	Povećanje trgovinskog i tekućeg deficita s tendencijom povećanja vanjske zaduženosti.
	Niska razina ostvarene privatizacije uz popratnu pojavu velikih društvenih devijacija i tenzija.

Makroekonomske pokazatelje hrvatskog gospodarstva danas objavljuje Hrvatska narodna banka (HNB) uz Državni zavod za statistiku (DZS) kao jedan od nositelja službene statistike RH. Recentni glavni makroekonomski pokazatelji hrvatskog gospodarstva prema HNB-u za

2016. i 2017. godinu javno su dostupni na mrežnim stranicama HNB-a i dani su u tablici 2. [8]

Tablica 2. Makroekonomski pokazatelji hrvatskog gospodarstva 2016. i 2017. [8]

(nastavak na narednoj stranici)

<i>Makroekonomski pokazatelji gospodarstva RH</i>	2016.	2017.
Površina (u km ²)	56 594	56 594
Broj stanovnika (u mil.)	4,174	4,125
BND (u mil. HRK, tekuće cijene)	351 349	365 643
BND (u mil. EUR, tekuće cijene)	46 664	49 013
BND po stanovniku (u EUR)	11 180	11 882
BND - realna godišnja stopa promjene (u %)	3,5	2,9
Prosječna godišnja stopa inflacije potrošačkih cijena	-1,1	1,1
Tekući račun platne bilance (u mil. EUR)	1 206	1 963
Tekući račun platne bilance (u % BDP-a)	2,6	4,0
Izvoz robe i usluga (u % BDP-a)	48,8	51,3
Uvoz robe i usluga (u % BDP-a)	46,0	49,1
Inozemni dug (u mil. EUR, na kraju razdoblja)	41 668	40 069
Inozemni dug (u % BDP-a)	89,3	81,8
Inozemni dug (u % izvoza robe i usluga)	182,9	159,5
Otplaćeni inozemni dug (u % izvoza robe i usluga)	34,9	32,0
Bruto međunarodne pričuve (u mil. EUR, na kraju razdoblja)	13 514	15 706

Bruto međunarodne pričuve (u mjesecima uvoza robe i usluga, na kraju razdoblja)	7,6	7,8
Nacionalna valuta: hrvatska kuna (HRK)	HRK	HRK
Devizni tečaj za 31. prosinca (HRK : 1 EUR)	7,5578	7,5136
Devizni tečaj za 31. prosinca (HRK : 1 USD)	7,1685	6,2697
Prosječni devizni tečaj (HRK : 1 EUR)	7,5294	7,4601
Prosječni devizni tečaj (HRK : 1 USD)	6,8037	6,6224
Neto pozajmljivanje (+) /zaduživanje (-) konsolidirane opće države (u mil. HRK)	-3 275	3 158
Neto pozajmljivanje (+) /zaduživanje (-) konsolidirane opće države (u % BDP-a)	-0,9	0,9
Dug opće države (u % BDP-a)	80,2	77,5
Stopa nezaposlenosti (prema definiciji ILO-a, stanovništvo starije od 15 god.)	13,1	11,2
Stopa zaposlenosti (prema definiciji ILO-a, stanovništvo starije od 15 god.)	44,6	45,8

Važno je istaknuti da prilikom razmatranja glavnih makroekonomskih pokazatelja valja razlikovati bruto domaći proizvod (BDP)¹ od bruto nacionalnog proizvoda (BND)². Naime, prema DZS-u: BND je jednak zbroju BDP-a i salda primarnih dohodaka s inozemstvom. [3]

Nakon što su identificirani makroekonomski rezultati tranzicije i recentni makroekonomski pokazatelji, valja istaknuti i ključno recentno globalno makroekonomsko zbivanje, odnosno posljednju makroekonomsku i gospodarstvenu krizu globalnog karaktera, koja je započela

¹ engl. *Gross Domestic Product* (GDP)

² engl. *Gross National Product* (GNP)

sredinom 2007. krizom tržišta nekretnina u Sjedinim Američkim Državama, a 2008. poprimila globalni karakter. Kriza je ostavila je još jedan značajan trag na hrvatsko gospodarstvo – **pad izravnih stranih ulaganja** (engl. *Foreign Direct Investments* ili FDI), ključnog pokretača razvoja i raspodjele proizvodnog znanja unutar pojedinog gospodarstva. [9 i 10]

Opća slika današnjih makroekonomskih pokazatelja hrvatskog gospodarstva u usporedbi s ostalim članicama EU, razlog je zašto se ključna gospodarstvena pitanja u Hrvatskoj, a s obzirom na opisanu recentnu globalnu krizu, izravnu ratnu štetu i makroekonomski rezultat tranzicije 90-ih, danas prvenstveno vezuju uz pojam *oporavka*, a tek nakon oporavka, *ubrzanje* rasta.

2.3. Europa 2020. i strategija gospodarstvenog razvoja


Preduvjet oporavku i ubrzanju rasta hrvatskog gospodarstva, prevladavajuće mišljenje akademske zajednice ekonomista ističe *strukturne reforme* i *fiskalnu konsolidaciju*. Jedna od strukturnih reformi svakako je *Europa 2020.* – *Europska strategija za pametan, održiv i uključiv rast*.

Europa 2020. desetogodišnja je strategija EU za rast i zapošljavanje za razdoblje od 2010. do 2020. godine, a ističe pet glavnih ciljeva: [11]

1. **zapošljavanje** (cilj je ostvariti da 75 % osoba u dobi od 20. do 64. godine do 2020. godine bude u radnom odnosu)
2. **istraživanje i razvoj** (cilj je ostvariti udio od 3 % BDP-a EU koji se ulaže u istraživanje i razvoj)
3. **klimatske promjene i energija** (cilj je ostvariti emisije stakleničkih plinova za 20 % niže od razina iz 1990., povećati udio energije dobivene iz obnovljivih izvora na ukupnih 20 %, te povećati energetske učinkovitosti za 20 %)
4. **obrazovanje** (smanjiti slučajeve prijevremenog napuštanja školovanja ispod 10 %, te postići najmanje 40 % osoba u dobi od 30 do 34 godine sa završenim visokim obrazovanjem)

5. **smanjenje broja ljudi koji žive u siromaštvu ili socijalnoj isključenosti** ili su izloženi riziku od takvog života (ostvariti smanjenje od najmanje 20 milijuna manje ljudi u toj situaciji).

Vlada RH je u skladu s referentnim okvirom *Europe 2020*. donijela niz drugih strategija koje predstavljaju gospodarstvenu razvojnu strategiju, ali strategija kao dokument istoimenog naziva (još) ne postoji (Slika 2.). Za potrebe ovog rada kao dokument eventualne strukturne reforme gospodarstva uzet će se *Strategija pametne specijalizacije*, odnosno *Industrijska strategija*. [12]



Slika 2. Strategije Republike Hrvatske s obzirom na referentni okvir *Europe 2020*. [12]

2.4. Izvoz RH s obzirom na indeks ekonomske složenosti

Statistika međunarodne robne razmjene čini važan dio svjetskog gospodarstva. Postoji opseg metodoloških područja koja su važna za definiciju i mjerenje međunarodnih robnih tokova. I zakonodavstvo EU i nacionalne prakse su, u većem dijelu, usklađene s recentnim preporukama Ujedinjenih naroda (UN) iz 1998. godine. U primjeni su dvije metodologije usko povezane s carinskim procedurama, a koje se koriste za mjerenje međunarodne robne razmjene. To su opći i specijalni trgovinski sustav. [13]

Opći trgovinski sustav je širi koncept i pod njim se bilježe agregati koji uključuju svu robu koja ulazi ili izlazi iz ekonomskog područja zemlje s izuzetkom tranzitne trgovine. [13]

Specijalni trgovinski sustav je uži koncept. Roba iz strane zemlje koja je primljena u carinsko skladište ne bilježi se u sustavu specijalne trgovine sve dok ne uđe u slobodno kretanje zemlje koja je robu primila (ili je smještena pod carinskim postupkom na unutarnju proizvodnju ili proizvodnju pod carinskim nadzorom). Slično tome, roba koja napušta carinsko skladište ne bilježi se kao izvoz. [13]

Najpodrobniji rezultati međunarodne robne razmjene koja se tiče EU objavljuje Statistički ured Europskih zajednica (EUROSTAT). Temelje se na tarifnoj i statističkoj međunarodnoj klasifikaciji poznatoj kao *Harmonizirani sustav* (HS)³. [13]

HS je višenamjenska klasifikacija za carinsku i statističku primjenu o karakteristikama ili materijalu proizvoda. Za potrebe analize podataka mogu se koristiti i druge klasifikacije. Određeni rezultati mogu se prikazati u skladu sa *Standardnom međunarodnom trgovinskom klasifikacijom* (SMTK)⁴, koju uređuje UN. [13]

U *Strategiji pametne specijalizacije Republike Hrvatske za razdoblje od 2016. do 2020. godine i akcijskog plana za provedbu strategije pametne specijalizacije za razdoblje 2016. do 2017. godine*, izdvojeno je 20 proizvoda na četveroznamenastoj razini SMTK koji su se najviše izvozili 2011. i 2012. godine. Poredani su po rangu složenosti od 1 do 786, pri čemu 1 označava najsloženiji (Tablica 3.). [14]

³ engl. *Harmonised System*

⁴ engl. *Standard International Trade Classification*

Međutim, iako je međunarodna UN-ova baza podataka o trgovinskoj razmjeni, uz *Atlas ekonomske složenosti* navedena kao izvor podataka u Vladinoj *Strategiji*, u usporedbi s podacima u spomenutim izvorima uočava se određeno nepodudaranje za iste proizvode u istom razdoblju (2011.–2012.) prema kôdovima SMTK (Tablica 3.). [15]

U tablici se posebno ističu izvozne skupine poput brodova i čamaca (kôd SMTK 7932) čiji je udio u izvozu u naglom padu kao posljedica dugogodišnjeg neurednog gospodarstvenog stanja hrvatskih brodogradilišta, a ne samo fluktuacije ponude i potražnje u brodograđevnom sektoru na svjetskoj razini: to je upravo u trenutku pisanja ovog rada iznimno značajno jer se brodovi i čamci (rang složenosti 272) prema ekonomiji složenosti klasificiraju kao složeni proizvodi ključni za ubrzanje rasta gospodarstva. Istodobno, u porastu je izvoz prerađenog drva listača (kôd SMTK 2483), koje po svojem rangu složenosti ne predstavlja proizvod za čiju su proizvodnju potrebna posebna proizvodna znanja, te stoga nema značajan utjecaj na ubrzanje rasta gospodarstva.

Tablica 3. Proizvodi koje najviše izvozi RH prema rangu ekonomske složenosti

(nastavak na narednoj stranici)

Redni broj	SMTK	Proizvod	Udio u izvozu 2011.–2012. godine prema Strategiji pametne specijalizacije, %	Udio u bruto izvozu 2011.–2012. godine prema Atlasu ekonomske složenosti, %	Udio u bruto izvozu 2016. godine prema Atlasu ekonomske složenosti, %	Rang složenosti
1	7932	Brodovi i čamci	7,21	3,86 (2011.) 2,45 (2012.) Ukupno: 6,31	0,98	272
2	5417	Lijekovi	3,79	1,74 (2011.) 1,91 (2012.) 3,65	2,23	161
3	7711	Električni transformatori	2,32	1,14 (2011.) 0,99 (2012.) 2,13	1	363
4	2483	Prerađeno drvo listača	2,18	0,97 (2011.) 1,05 (2012.) 2,02	1,26	687
5	6842	Prerađeni aluminij i legure aluminija	1,89	0,86 (2011.) 0,91 (2012.) 1,77	0,43	317
6	5621	Dušična gnojiva	1,73	0,7 (2011.) 0,76 (2012.) 1,46	0,53	641

7	7938	Posebni plutajući objekti	1,68	1,23 (2011.) 0,45 (2012.) 1,68	0,24	631
8	8211	Stolice i sjedalice	1,67	0,62 (2011.) 0,71 (2012.) 1,33	0,93	318
9	2820	Željezni i čelični otpad	1,62	0,94 (2011.) 0,83 (2012.) 1,77	0,31	542
10	612	Rafinirani šećer	1,4	0,54 (2011.) 0,57 (2012.) 1,11	0,43	599
11	7731	Električne žice	1,35	0,55 (2011.) 0,64 (2012.) 1,19	0,48	441
12	980	Jestivi proizvodi, d. n.	1,31	0,52 (2011.) 0,58 (2012.) 1,1	0,61	424
13	8510	Obuća	1,26	0,76 (2011.) 0,7 (2012.) 1,46	0,69	541
14	9710	Zlato, nemonetarno	1,16	0,25 (2011.) 0,9 (2012.) 1,15	0,26	756
15	5629	Gnojiva	1,15	0,53 (2011.) 0,48 (2012.) 1,01	0,21	597
16	7284	Specijalizirani industrijski strojevi i dijelovi, d. n. ⁵	1,1	0,5 (2011.) 0,55 (2012.) 1,05	0,59	1
17	7849	Ostali dijelovi vozila	1,09	0,52 (2011.) 0,48 (2012.) 1	0,78	62
18	6612	Cement	1,02	0,44 (2011.) 0,44 (2012.) 0,88	0,44	648
19	2882	Ostali obojeni osnovni metali	1	0,46 (2011.) 0,51 (2012.) 0,97	0,24	529
20	7721	Razvodne ploče, releji i osigurači	0,96	0,4 (2011.) 0,48 (2012.) 0,88	0,54	127

⁵ d.n. je kratica za "drugdje nespomenuto" (engl. n.e.c. ili *Not Elsewhere Classified*)

3. INDEKS EKONOMSKE SLOŽENOSTI

Nakon stoljeća sporog i nejednolikog rasta, početak demografske ekspanzije vezuje se uz izum i usavršavanje uporabljivog parnog stroja⁶ ili prvu industrijsku revoluciju koja je tijekom 18. i 19. stoljeća označila prijelaz sa manufakturnog na tvornički oblik rada ili prijelaz iz poljoprivrednog u takozvano **industrijsko** društvo. [16]

Izraz *Industrija 4.0* (njem. *Industrie 4.0*) prvi se put spominje na svjetski poznatom sajmu **Hannover Messe** u Njemačkoj 2011. godine, a označava četvrtu u nizu tehnoloških revolucija koja je, unatoč tumačenjima neznanstvenih izvora, (još uvijek) vizija ili globalni koncept *digitalne transformacije industrije*. Temeljno obilježje četvrte industrijske revolucije je interakcija virtualnog i stvarnog, odnosno upotreba pametne tehnologije i podataka u stvarnom vremenu kroz internet stvari (engl. *Internet of Things*), računalstvo u oblaku (engl. *Cloud Computing*), velike setove podataka (engl. *Big Data*) i druge inovacije digitalizacije i robotizacije, s ciljem povećanja produktivnosti i smanjenja troškova. [17 i 18]

Razvijena suvremena društva tako su, karakterizirana ubrzanim tehnološkim napretkom i već desetljećima aktualnom globalizacijom, sposobna taložiti veliko proizvodno znanje unutar sebe. Komadiće tog golemog proizvodnog znanja čine pojedinci čija posebna znanja stvaraju raznolikost na nacionalnoj, ili opet – globalnoj razini. Međutim, najrazvijenija suvremena društva nisu „pametnija“ zbog posebnih znanja pojedinaca, već zbog toga što takva društva znaju kako kombinirati ta znanja kako bi u konačnici proizvela lepezu složenijih, „pametnijih“ proizvoda. Izvoz takvih proizvoda u većoj mjeri pridonosi rastu i ubrzanju rasta gospodarstva neke zemlje. [19]

Postoji više pokazatelja kojima se nastoji istražiti korelacija između drugih čimbenika koji uzrokuju rast i ubrzanje rasta gospodarstva, a to su i **pokazatelji rada državnih institucija, ljudskog kapitala ili kompetitivnosti**. Oni uz indeks ekonomske složenosti zapravo ilustriraju različite aspekte iste složene (gospodarstvene) stvarnosti. [19]

⁶ Heronova kugla se smatra prvim parnim strojem u povijesti, a konstruirao ju je Heron iz Aleksandrije, u 1. stoljeću. Prvi uporabljivi parni stroj konstruirali su Englezi Thomas Savery (1650.–1715.) i Thomas Newcomen (1663.–1729.), a prvi parni stroj nalik suvremenima izradio je James Watt u drugoj polovici 18. stoljeća.

Svjetska banka od 1996. godine objavljuje šest pokazatelja svjetskog upravljanja (engl. *Worldwide Governance Indicators*) za mjerenje kvalitete rada državnih institucija. Ti se pokazatelji temelje na izravnoj povezanosti rada državnih institucija i rasta i smanjenja siromaštva. Mjera u kojoj državne institucije omogućavaju pojedincima i poduzećima suradnju, razmjenu znanja i stvaranje složenijih proizvoda, određuje vrstu industrije koju država može podržati. U tablici 4. prikazani su pokazatelji WGI za Hrvatsku za 1996., 2016. i 2017. godine. [19 i 20]

U tablici 4. vidljivo je kako su se svi pokazatelji od godine prvog objavljivanja (1996.) vidno poboljšali. Povećao se broj nezavisnih izvora podataka, kao i ocjena vlasti za svaki pokazatelj. Međutim, usporedbom 2016. i 2017. godine, u pokazateljima *vladavine prava* i *kontrole korupcije* uočljiv je trend pada poretka u odnosu na druge zemlje u postocima od 0 do 100 i to za pokazatelj *vladavine prava* sa 66,35 % na 63,46 % i *kontrolu korupcije* sa 62,5 % na 61,06 %. [20]

U izračunu pokazatelja *ljudskog kapitala*, standardne su varijable broj godina formalnog obrazovanja koje ima pojedinac u trenutku kada postaje radno sposoban (prema Međunarodnoj organizaciji rada – 15 godina starosti) ili broj upisanih u sustav formalnog obrazovanja. Budući da ti pokazatelji ne uzimaju u obzir kvalitetu obrazovanja, koriste se i standardizirani međunarodni ispiti kao što je Program za međunarodnu procjenu studenata (PISA) razvijen od strane Organizacije za ekonomsku suradnju i razvoj (OECD). [19]

Svjetski indeks kompetitivnosti (engl. *Global Competitiveness Index*) pokazatelj je Svjetskog ekonomskog foruma, odnosno mjera institucija, politika i čimbenika koji određuju održivu sadašnju i srednjoročnu razinu gospodarstvenog rasta. Indeks kompetitivnosti objavljuje se od 1979. godine. [19]

Tablica 4. Pokazatelji upravljanja Svjetske banke (WGI) za Hrvatsku [20]

Pokazatelji ⁷	Godina	Broj nezavisnih izvora podataka na kojima se temelji pokazatelj	Ocjena vlasti (od –2,5 do +2,5), više vrijednosti označavaju bolje upravljanje	Poredak u odnosu na druge zemlje (od 0 do 100 %), više vrijednosti označavaju bolji položaj
Otvorenost i odgovornost (engl. <i>Voice and Accountability</i>)	1996.	5	–0,16	45,00
	2016.	13	0,52	65,02
	2017.	13	0,51	64,04
Politička stabilnost i odsustvo nasilja ili terorizma (engl. <i>Political Stability and Absence of Violence or Terrorism</i>)	1996.	3	–0,04	47,34
	2016.	9	0,66	68,10
	2017.	9	0,75	71,90
Učinkovitost vlasti (engl. <i>Government Effectiveness</i>)	1996.	2	0,10	58,47
	2016.	9	0,50	70,19
	2017.	9	0,58	72,60
Kvaliteta regulacije (engl. <i>Regulatory Quality</i>)	1996.	4	–0,17	49,46
	2016.	11	0,36	65,87
	2017.	10	0,42	68,75
Vladavina prava (engl. <i>Rule of Law</i>)	1996.	6	–0,63	31,16
	2016.	13	0,41	66,35
	2017.	13	0,33	63,46
Kontrola korupcije (engl. <i>Control of Corruption</i>)	1996.	3	–0,58	32,80
	2016.	13	0,20	62,50
	2017.	13	0,19	61,06

⁷ Prijevod naziva pokazatelja s engleskog na hrvatski izveden prema Galović, M.: *Statistički pokazatelji raširenosti korupcije u pravosuđu*, Pravnik: časopis za pravna i društvena pitanja 48 (2015.) 98, str. 108.

Nadalje, kao što je već rečeno, **indeks ekonomske složenosti** (engl. *Economic Complexity Index*) holistička je mjera proizvodnih sposobnosti velikih ekonomskih sustava, obično gradova, regija ili zemalja. Indeks ekonomske složenosti nastoji obuhvatiti mjeru ukupnog proizvodnog znanja alociranog unutar populacije, koje prvenstveno korelira s njenom raznolikošću, a na temelju njenih gospodarstvenih aktivnosti. Indeks ekonomske složenosti formulirali su i objavili profesori César A. Hidalgo s Instituta za tehnologiju u Massachusettsu i Ricardo Hausmann sa Sveučilišta Harvard 2009. godine.

U formulaciji indeksa, Hidalgo i Hausmann statističkim i matematičkim modelima ukazuju da indeks ekonomske složenosti u obzir uzima i „skriveno“ proizvodno znanje u lepezi gospodarstvenih aktivnosti neke zemlje, a ne samo ono formalno, te bolje predviđa gospodarstvo od svjetskog indeksa kompetitivnosti. **Indeks ekonomske složenosti stoga nije samo opisna (deskriptivna), već i predviđajuća (prediktivna) mjera gospodarstvenog rasta.** [19]

3.1. Mjerenje indeksa ekonomske složenosti

Prema Hidalgo i Hausmannu postoji razlika između onoga što zemlja proizvodi i proizvodnog znanja koje zemlja alocira unutar svoje populacije. Ako proizvod zahtijeva posebna proizvodna znanja ili njihovu kombinaciju, zemlje koje ih proizvode alociraju ta (skrivena) proizvodna znanja unutar svoje populacije. Količinu proizvodnog znanja unutar populacije, zemlja iskazuje u svojoj proizvodnoj raznolikosti (engl. *Diversity*) ili ubikviteta⁸ ili svenazočnosti različitih proizvoda (engl. *Ubiquity*). [19].

U jediničnoj matrici (M_{cp}), 1 označava proizvodnju određenog proizvoda (engl. *p – Product*) u nekoj zemlji (engl. *c – Country*), a 0 suprotno. Raznolikost i svenazočnost mjere se sumama redova i stupaca te matrice prema formulama (1) i (2): [19]

$$k_{c,0} = \sum_p M_{cp} \quad (1)$$

$$k_{p,0} = \sum_c M_{cp} \quad (2)$$

Kako bi se izračunali precizniji podaci o broju proizvodnih znanja u zemlji ili broju proizvodnih znanja koje zahtijeva proizvod, potrebno je korigirati podatke o raznolikosti i

⁸ **Ubikvitēt**, prema Hrvatskom jezičnom portalu znači sveprisutnost, posvudašnjost, svenazočnost, sposobnost i/ili svojstvo čega da je prisutno na svakom mjestu.

svenazočnosti koristeći međusobnu korekciju raznolikosti svenazočnošću i obratno. Za zemlje je potrebno izračunati prosječnu svenazočnost proizvoda koje neka zemlja izvozi, i prosječnu raznolikost proizvoda zemalja koje proizvode iste proizvode. Za proizvode je potrebno izračunati prosječnu raznolikost zemalja koje proizvode te proizvode i prosječnu svenazočnost drugih proizvoda koje te zemlje proizvode. [19]

Relacije su određene formulama (3) i (4): [19]

$$k_{c,N} = \frac{1}{k_{c,0}} \sum_p M_{cp} \cdot k_{p,N-1} \quad (3)$$

$$k_{p,N} = \frac{1}{k_{p,0}} \sum_p M_{cp} \cdot k_{c,N-1} . \quad (4)$$

Kada se (4) uvrsti u (3) dobije se: [19]

$$k_{c,N} = \frac{1}{k_{c,0}} \sum_p M_{cp} \frac{1}{k_{p,0}} \sum_{c'} M_{c'p} \cdot k_{c',N-2} . \quad (5)$$

Sređivanjem izraza (5) dobiju se izrazi (6) i (7): [19]

$$k_{c,N} = \sum_{c'} k_{c',N-2} \sum \frac{M_{cp} M_{c'p}}{k_{c,0} k_{p,0}} \quad (6)$$

$$k_{c,N} = \sum_{c'} M_{cc'} k_{c',N-2} \quad (7)$$

Iz izraza (7) sređivanjem slijedi izraz (8): [19]

$$\tilde{M}_{cc'} = \sum_p \frac{M_{cp} M_{c'p}}{k_{c,0} k_{p,0}} . \quad (8)$$

Izraz (7) je zadovoljen kada je $k_{c,N} = k_{c,N-2} = 1$ što je svojstveni vektor matrice $\tilde{M}_{cc'}$ koja je povezana s najvećim svojstvenim vrijednostima. Kako je svojstveni vektor jedinični vektor, ne sadrži nikakve informacije. Stoga Hidalgo i Hausmann koriste svojstveni vektor povezan s drugim najvećim svojstvenim vrijednostima. Takav svojstveni vektor sadrži najveću vrijednost varijance u sustavu i mjera je ekonomske složenosti. [19]

Indeks ekonomske složenosti (ECI) definiran je sljedećim izrazom: [19]

$$ECI = \frac{\bar{K} - \langle \bar{K} \rangle}{\text{stdev}(\bar{K})} \quad (9)$$

gdje su:

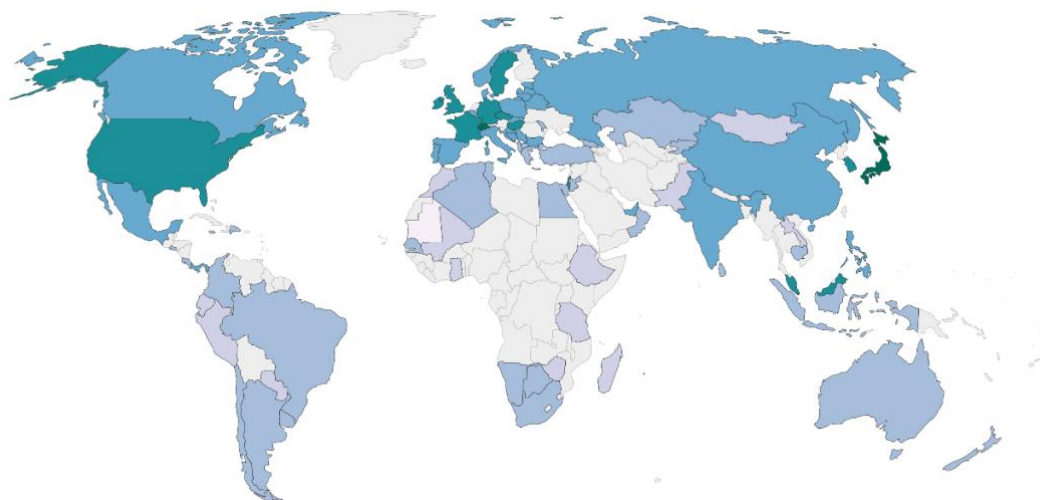
\bar{K} – svojstveni vektor $\tilde{M}_{cc'}$, koji povezuje druge najveće svojstvene vrijednosti,

$\langle \rangle$ – prosjek,

stdev – standardna devijacija.

Slika 3. prikazuje geografsku kartu zemalja svijeta u 2016. s obzirom na indeks ekonomske složenosti njihovih gospodarstava, gdje se gradacija od tamnozelenog (zemlje s najvećim indeksom ekonomske složenosti) prema svijetloplavom (zemlje s najmanjim indeksom ekonomske složenosti) poklapa sa socijalnim, ekonomskim i političkim fenomenom globalne podjele svijeta na „bogati“ sjever i „siromašni“ jug. S aspekta gospodarstvene razvijenosti, globalni sjever koji se još naziva i *Zapadnim svijetom* ili *zemljama Prvog svijeta* alocira 90 % proizvodne industrije ili četiri petine svjetskih prihoda. [21]

ECI je za RH prema recentnim podacima iz 2017. iznosio 0,623091 te se ona u ukupnom poretku zemalja nalazila na 36. mjestu od ukupno 129 zemalja. [22]



Slika 3. Geografska karta zemalja s obzirom na indeks ekonomske složenosti njihovih gospodarstava iz 2016. [22]

3.2. Atlas ekonomske složenosti

Atlas ekonomske složenosti obuhvaća *on-line* alate za vizualizaciju trgovinskih podataka i složenosti, odnosno njihov opis (deskripciju) i predviđanje (predikciju), a temelji se na izračunu indeksa ekonomske složenosti.

Atlas obuhvaća sljedeće alate: [23]

1. alate za vizualizaciju trgovinskih podataka: „stablo proizvoda“, geografsku kartu i složene karte,

2. alate za vizualizaciju složenosti: prostor proizvoda, grafikone izvodljivosti, i vizualizaciju pomoću „prstena“.

Alati analiziraju i sintetiziraju trgovinske podatke iz dviju baza podataka (UN COMTRADE i baza podataka Statistike trgovine Međunarodnog monetarnog fonda) te nastoje odgovoriti na gospodarstvena pitanja poput: *što zemlja uvozi i izvozi? Kako se njena trgovina razvijala u vremenu? Koji su pokretači rasta izvoza?* [23]

Rezultat analize i sinteze trgovinskih podataka u *Atlasu* jesu: [23]

1. struktura izvoza ili uvoza zemalja ili prema proizvodima,
2. gustoća trgovinske razmjene između zemalja,
3. dinamika trgovine tijekom vremena,
4. povezanost proizvoda i putovi ka diverzifikaciji,
5. putovi diverzifikacije iz postojećeg izvoza u srodne proizvode,
6. novi proizvodi visokog potencijala za diverzifikaciju.

3.3. Prostor proizvoda


Prostor proizvoda (engl. *Product Space*) jedan je od alata za vizualizaciju složenosti. On prikazuje *putove* kojima se posebno proizvodno znanje u nekoj zemlji *taloži*, njene trenutne proizvodne sposobnosti, odnosno posebna proizvodna znanja unutar njena gospodarstva. [19 i 23]

Oblik prostora proizvoda pokazuje kako diverzifikacija funkcionira u praksi: zemlje kreću od proizvoda koje znaju proizvoditi do proizvoda koji su bliski njenom proizvodnom programu, odnosno zahtijevaju slična znanja. Nepravilnost prostora znači da se diverzifikacija odvija preferencijalno; zemlje koje imaju gusto ispunjeno središte prostora proizvoda imaju veće mogućnosti za diverzifikaciju u usporedbi sa zemljama čiji je prostor proizvoda ispunjen samo na periferiji. Valja istaknuti kako se prostor proizvoda temelji na trgovinskim podacima o izvozu, ali izvoz ne znači uvijek i proizvodnju samog proizvoda unutar razmatranog gospodarstva. [19 i 23]

Indeks iskazane komparativne prednosti (engl. *Revealed Comparative Advantage* ili RCA) mjera je koja pojedinu zemlju definira kao izvoznika pojedinog proizvoda, ali ne u odnosu na


trgovinske podatke izvozi li zemlja taj proizvod ili ne, već u odnosu na *relativnu prednost* ili *relativan zaostatak* kojeg gospodarstvo neke zemlje ostvaruje u izvozu tog proizvoda u odnosu na njegov općenit udio u svjetskoj trgovini. [19 i 23]

Udaljenost skupina proizvoda (od 0 do 1) u prostoru proizvoda predstavlja opseg već postojećih sposobnosti, odnosno (posebnih) proizvodnih znanja potrebnih za njihovu proizvodnju, u mjeri u kojoj su ti proizvodi bliski trenutnom izvoznom programu gospodarstva te zemlje (Slika 4.). [19 i 23]




Slika 4. Prostor proizvoda s pripadajućim simbolima koji predstavljaju različite skupine proizvoda [19]

Prema recentnom (2017.) poretku gospodarstava zemalja, na začelju se nalazi Nigerija čiji je ECI negativan: $-1,90268$. U prostoru proizvoda Nigerije (Slika 5.) uočljiva je niska raznolikost i predominantne izvozne skupine: naftna ulja i sirovine (smeđe) te poljoprivredni proizvodi (žuto) čija eksploatacija ne zahtijeva posebna proizvodnja znanja. [23]



Slika 5. Prostor proizvoda gospodarstva Nigerije s obzirom na izvoz u 2016. [23]

Najveći indeks ekonomske složenosti ima japansko gospodarstvo (ECI: $2,30938$). U prostoru proizvoda japanskog gospodarstva uočljiva je raznolikost i svenazočnost složenih proizvoda poput: strojeva (plavo), elektronike (svijetloplavo) i kemikalija (ljubičasto) čija proizvodnja zahtijeva mnoštvo posebnih proizvodnih znanja (Slika 6.). [23]



Slika 6. Prostor proizvoda japanskog gospodarstva s obzirom na izvoz u 2016. [23]

3.4. Indeks složenosti proizvoda

Analogno indeksu ekonomske složenosti, Hidalgo i Hausmann su razvili indeks složenosti proizvoda (engl. *Product Complexity Index*). S obzirom na simetričnost matematičke formulacije indeksa ekonomske složenosti (ECI) i indeksa složenosti proizvoda (PCI), oni imaju istu matematičku definiciju opisanu u točki 3.1., ali umjesto indeksa zemalja (c) PCI sadrži indeks proizvoda (p). Shodno tome, indeks složenosti proizvoda definiran je izrazom: [19]

$$PCI = \frac{\vec{Q} - \langle \vec{Q} \rangle}{\text{stdev}(\vec{Q})} \quad (10)$$

gdje je:

\vec{Q} – svojstveni vektor \tilde{M}_{pp} , koji povezuje druge najveće svojstvene vrijednosti.

U tablicama 5. i 6. dan je pregled najsloženijih i najjednostavnijih proizvodnih skupina prema kôdu HS (prema reviziji HS-a iz 2007.) za 2017. godinu, a s obzirom na indeks složenosti proizvoda. Kao izvor podataka za 2017. korištene su mrežne stranice Opservatorija za ekonomsku složenost (OEC) Instituta za tehnologiju u Massachusettsu. Važno je naglasiti kako je PCI podložan promjenama shodno primjerice inovacijama u proizvodnji (na globalnoj razini) stoga su se poredci pet najsloženijih i pet najmanje složenih proizvoda nekoliko puta mijenjali i nastaviti će se mijenjati u narednim godinama. [19]

Harmonizirani sustav opisa i kodiranja robe (engl. *Harmonized Commodity Description and Coding Systems* ili HS) je međunarodna nomenklatura za klasifikaciju robe kojom se trguje u carinske svrhe. HS sadrži približno 5 300 opisa proizvoda raspoređenih u 99 poglavlja i 21 odjeljak. Šest znamenki kôda HS mogu se podijeliti na tri dijela. Prve dvije znamenke (HS-2 razina) označavaju poglavlje u kojemu je roba razvrstana: 09 = kava, čaj, mate⁹ i začini. Sljedeće dvije znamenke (HS-4 razina – ukupno četiri znamenke kôda) označavaju grupacije unutar tog poglavlja: 0902 = čaj, aromatiziran ili bez dodatnih aroma. Sljedeće dvije znamenke (HS-6 razina – ukupno šest znamenki kôda) definiraju robu još detaljnije: 090210 = zeleni čaj (nefermentiran). Do razine HS-6, sve zemlje klasificiraju proizvode na isti način

⁹ Mate je zimzeleno drvo zelenih listova i crvenih bobica karakterističnog izgleda koje uspijeva samo u Južnoj Americi gdje ga još zovu i "napitkom bogova". Brazil, Argentina i Paragvaj su najveći proizvođači te ujedno i potrošači Yerba Mate čaja.

(postoji nekoliko iznimki kada neke zemlje primjenjuju stare verzije HS-a). Harmonizirani sustav uveden je 1988. godine i usvojen je u većini zemalja svijeta. Prošlo je nekoliko promjena u klasifikaciji proizvoda. Te se promjene nazivaju revizijama i stupile su na snagu 1996., 2002., 2007., 2012. i 2017. godine. [24]

3.5. Najsloženiji i najjednostavniji svjetski i hrvatski proizvodi prema indeksu složenosti proizvoda u 2017. godini

U tablici 5. zvjezdicom (*) su označeni proizvodi koje je Hrvatska izvozila, prema posljednjim podacima o izvozu u *Atlasu ekonomske složenosti* iz 2016. Dakle, najsloženiji su proizvodi u hrvatskom izvozu u 2016. godini bili: **2905 HS4 – ciklični alkoholi i njihovi halogeni-, sulfo-, nitro- ili nitrozo-derivati**¹⁰. Izvoz ove skupine imao je protuvrijednost neto **399 tisuća USD**, a strukturu zemalja izvoza sačinjavale su u najvećoj mjeri susjedne zemlje: Slovenija (57,97 %), Bosna i Hercegovina (21,16 %) i Srbija (7,79 %).

Zatim slijedi skupina **4002 HS4 – sintetički kaučuk i faktis dobiven iz ulja, u primarnim oblicima ili u pločama, listovima ili vrpčama** čiji je neto izvoz iznosio **607 tisuća USD**, a glavne zemlje izvoza bile su Bosna i Hercegovina (50,72 %) i Rusija (48,54 %).

I naposljetku **2903 HS4 – halogeni-derivati ugljikovodika** čiji je neto izvoz iznosio **92,7 tisuća USD**, a strukturu zemalja izvoza uglavnom susjedne zemlje: Bosna i Hercegovina (41,32 %), Srbija (21,32 %), ali u manjoj mjeri i nesusjedne zemlje: Makedonija (18,06 %) i Indija (12,68 %). [15 i 23]

Tablica 5. Najsloženiji proizvodi prema indeksu složenosti proizvoda u 2017. godini [23]

<i>Poredak</i>	<i>Kôd HS4</i>	<i>Proizvod</i>¹⁰	<i>Indeks složenosti proizvoda (PCI)</i>
1	8461	<i>Alatni strojevi za dugohodno blanjanje, kratkohodno blanjanje, dubljenje ili provlačenje, ozublivanje, brušenje ili završnu obradu ozubljenja, piljenje, rezanje reznom pločom te ostali alatni strojevi za obradu kovina ili kermeta odvajanjem čestica, nespomenuti niti uključeni na drugom mjestu</i>	2,985
2	2922	<i>Amino spojevi s kisikovom skupinom</i>	2,787
3*	2905	<i>Aciklični alkoholi i njihovi halogeni-, sulfo-, nitro- ili nitrozo-derivati</i>	2,711
4*	4002	<i>Sintetički kaučuk i faktis dobiven iz ulja, u primarnim oblicima ili u pločama, listovima ili vrpčama</i>	2,683
5*	2903	<i>Halogeni-derivati ugljikovodika</i>	2,572

¹⁰ Nazivi robe, odnosno proizvoda prema HS nomenklaturi preuzeti su s mrežnih stranica *Integriranog sustava za upravljanje tarifom* (engl. *Integrated Tariff Management System* ili ITMS) Carinske Uprave RH. [25]

Tablica 6. Najjednostavniji proizvodi prema indeksu složenosti proizvoda u 2017. godini [23]

Poredak	Kôd HS4	Proizvod¹⁰	Indeks složenosti proizvoda (PCI)
6218	5307	<i>Pređa od jute ili drugih tekstilnih vlakana od drvenog lika</i>	–4,529
6217	4407	<i>Drvo obrađeno po dužini piljenjem ili glodanjem, rezano ili ljušteno, neovisno je li blanžano, brušeno ili spojeno na krajevima ili ne, debljine veće od 6 mm</i>	–3,473
6216	0801	<i>Kokosov orah, brazilski orah i indijski oraščić, svježi ili suhi, neovisno jesu li oljušteni ili oguljeni ili ne</i>	–3,327
6215	5303	<i>Juta i ostala tekstilna vlakna od drvenog lika (isključujući lan, pravu konoplju i ramiju), sirova ili prerađena, ali nepredena; kućina i otpaci od tih vlakana</i>	–3,007
6214	1801	<i>Kakao u zrnu, cijeli ili lomljeni, sirovi ili prženi</i>	–2,96

4. ATLAS EKONOMSKE SLOŽENOSTI REPUBLIKE HRVATSKE

4.1. Prostor proizvoda hrvatskog gospodarstva u 2016. godini

Trgovinski podaci u prostoru proizvoda dohvaćaju se iz baze podataka Statističkog odjela Ujedinjenih naroda (engl. *United Nations International Trade Statistics Database* – UN COMTRADE). Sirovi trgovinski podaci¹¹ dohvaćaju se iz baze podataka Statistike trgovine Međunarodnog monetarnog fonda (MMF). Prostor proizvoda koristi i različite tipove klasifikacije robne razmjene – Harmonizirani sustav (HS) i Standardnu međunarodnu trgovinsku klasifikaciju (SMTK). HS podaci nude suvremenu i detaljnu klasifikaciju robe, ali obuhvaćaju relativno kraće vremensko razdoblje. SMTK podaci nude duže vremenske serije, ali obuhvaćaju manje robe. Slika 7. prikazuje prostor proizvoda hrvatskog gospodarstva u 2016. prema HS4 klasifikaciji robe. [15]

Indeks iskazane komparativne prednosti u vrijednosti $RCA \geq 1$ u prostoru proizvoda znači da prikazane proizvodne skupine Hrvatska izvozi više od svog “poštenog udjela” (engl. *Fair Share*) ili udjela koji je jednak ili veći od udjela tih proizvodnih skupina na svjetskom tržištu. [15 i 19]


U prostoru proizvoda hrvatskog gospodarstva u 2016. pojavljuje se devet proizvodnih skupina sirovina i roba od mogućih 33 (s izuzetkom skupine „nepoznato“), prema redoslijedu od najvećeg udjela u izvozu prema najmanjem (Slika 7.): [15]

1. poljoprivredna (svijetložuto) 11,4 %
2. kemikalije (ružičasto) 7,07 %
3. strojevi (plavo) 6,17 %
4. tekstil (zeleno) 6 %
5. minerali (svijetlosmeđe) 5,38 %

¹¹ Prema Rozga, A., Grčić, B.: *Poslovna statistika*, Ekonomski fakultet Split, Split, 2009., str. 3.: „... statistika kao posebna znanstvena disciplina uključuje dva specifična segmenta: deskriptivnu i inferencijalnu statistiku. Deskriptivna statistika temelji se na tzv. potpunom obuhvatu statističkog skupa, te primjenom odgovarajućih tehnika sirovu statističku građu svodi na lakše razumljivu i svrishodnu formu, pri tom se takozvani **sirovi podaci** organiziraju se u distribucije frekvencija, prezentiraju se odgovarajućim grafikonima, te se na taj način pripremaju za detaljniju analizu.“

6. elektronika (svijetloplavo) 4,42 %
7. prijevozna sredstva (ljubičasto) 3,53 %
8. metali (crveno) 3,33 %
9. proizvodi od kamena (žuto) 1,64 %.

Ukupna bruto vrijednost hrvatskog izvoza u 2016. iznosila je 27,1 milijardi USD. [15]



Slika 7. Prostor proizvoda hrvatskog gospodarstva s obzirom na izvoz u 2016. [15]

4.1.1. Poljoprivredni proizvodi

Od poljoprivrednih proizvoda (jednozamenkasti kôd HS1: 1) najviše se izvezio proizvod **HS4 4407 – drvo obrađeno po dužini piljenjem ili glodanjem, rezano ili ljušteno, neovisno je li blanjano, brušeno ili spojeno na krajevima ili ne, debljine veće od 6 mm** (1,28 %), koji prema svojem indeksu složenosti proizvoda ($PCI = -3,473$) kako je opisano u točki 3.3., spada u najmanje složene proizvode koji najmanje pridonose rastu i ubrzanju rasta gospodarstva neke zemlje (Slika 8.). [15 i 23]




Slika 8. Prostor poljoprivrednih proizvoda hrvatskog gospodarstva u 2016. godini [15]

4.1.2. Kemikalije

Od kemikalija (HS1: 5, Slika 9.) se najviše izvezio proizvod **HS4 3004 – lijekovi koji se sastoje od pomiješanih ili nepomiješanih proizvoda za terapijsku ili profilaktičnu uporabu, pripremljeni u odmjerene doze (uključujući i one u oblicima za transdermalni sustav primjene) ili u oblike ili pakiranja za pojedinačnu prodaju** (2,18 %). [15]


Velika poduzeća koja se ističu u izvozu ove skupine proizvoda jesu: **Pliva Hrvatska d.o.o.** i **Oktal-Pharma d.o.o.** u Zagrebu, **Belupo d.d.** u Koprivnici i **Jadran-galenski laboratorij d.d.** u Rijeci. [26]



Slika 9. Prostor proizvoda kemikalija u hrvatskom gospodarstvu u 2016. [15]

4.1.3. Strojevi

Najveći dio izvoza strojeva (HS1: 7, Slika 10.) sačinjavali su **HS4 9302 – revolveri i pištolji** (0,4 %), **HS4 8477 – strojevi za obradu i preradu gume ili plastične mase ili za izradu proizvoda od tih materijala** (0,38 %) i **HS4 8480 – kalupnici za ljevaonice kovina; temeljne ploče; modeli za izradu kalupa; kalupi za kovine (osim kalupa za ingote), metalni karbidi, staklo, mineralne tvari, guma i plastične mase** (0,32 %). [15]




Slika 10. Prostor proizvoda strojeva u hrvatskom gospodarstvu u 2016. [15]

Veliko poduzeće koje se ističe u izvozu revolvera i pištolja je **HS PRODUKT d.o.o.** u Karlovcu. U izvozu strojeva za obradu i preradu gume ili plastične mase ističu se veliko poduzeće čije je podrijetlo kapitala međutim u cijelosti njemačko – **Harburg-Freudenberger Belišće d.o.o.** i srednje poduzeće **TMT d.o.o.** u Čakovcu. U izvozu skupine kalupnika, temeljnih ploča i modela za izradu kalupa te kalupa za kovine, metalnih karbida i stakla, ističu se dva poduzeća od kojih je jedno veliko u cijelosti belgijskog porijekla kapitala – **OMCO Croatia d.o.o.** u Humu na Sutli, dok je drugo srednje poduzeće **LTH Metalni lijev d.o.o.** u Benkovcu. [26]

4.1.4. Tekstili

Od tekstila (HS1 1, Slika 11.) se najviše izvezio proizvod **HS4 9401 – sjedala (osim onih iz tarifnog broja 9402), neovisno može li ih se pretvoriti u ležajeve ili ne, i njihovi dijelovi** (0,89 %). U izvozu ove skupine ističu se veliko poduzeće **SPIN VALIS d.d.** u Požegi i srednje poduzeće **Drvena industrija Klana d.d.** [15 i 26]



Slika 11. Prostor tekstilnih proizvoda u hrvatskom gospodarstvu u 2016. [15]

Među opisanim proizvodima razine klasifikacije HS4 (≥ 6 % udjela u cjelokupnom izvozu RH), najsloženiji je **HS4 8477 – strojevi za obradu i preradu gume ili plastične mase** (PCI = 1,693), dok je najmanje složen proizvod **HS4 4407 – drvo** (PCI = -3,473). [15 i 23]

Uočljivo je kako poljoprivredni proizvodi općenito imaju najmanji indeks složenosti proizvoda, a njihov je udio u izvozu najveći (11,4 %). Negativna vrijednost indeksa složenosti drva predstavlja slučaj kada stupanj složenosti proizvoda premašuje tržištu potreban stupanj složenosti proizvoda. U takvom slučaju stvara se nepotrebna složenost bez dodatne vrijednosti. [27]

4.2. Najsloženiji proizvodi u 2016. godini s obzirom na njihovu globalnu raspodjelu (RCA) i indeks složenosti proizvoda (PCI)

Nakon pregleda najvećih izvoznih skupina (udio u izvozu $\geq 6\%$ te $RCA \geq 1$) u prostoru proizvoda hrvatskog gospodarstva u 2016. i njihove proizvodne složenosti, valja identificirati općenito najsloženije proizvode u izvozu.

Kako autori (Hidalgo i Hausmann) indeksa ekonomske složenosti (ECI), indeksa složenosti proizvoda (PCI) i *Atlasa ekonomske složenosti* dolaze iz dvije različite ustanove (MIT i Harvard), tako postoje i dvije inačice mrežnih stranica na kojima su dostupni spomenuti alati: inačica Opservatorija za ekonomsku složenost Instituta za tehnologiju u Massachusettsu (OEC) i inačica Centra za međunarodni razvoj Sveučilišta Harvard (CID). CID, međutim, jedini sadrži cjeloviti *Atlas* sa svim pripadajućim alatima. Prednost OEC-ove inačice je što sadrži ažurnije liste proizvoda poredanih prema indeksu složenosti proizvoda. [23 i 28]

U tablicama 5. i 6. (točka 3.4.) navode se najsloženiji i najmanje složeni proizvodi prema listama OEC-a iz 2017., dok se u ovome poglavlju koje se bavi prostorom proizvoda hrvatskog gospodarstva, za identifikaciju prisustva ostalih najsloženijih proizvoda (do 20) u hrvatskom izvozu, koriste CID-ovi mrežni izvori podataka iz 2016. godine.

Tablica 7. Najsloženiji proizvodi u izvozu RH u 2016. [15 i 29]

(nastavak na narednim stranicama)

<i>Poredak</i>	<i>Kôd HS4</i>	<i>Proizvod</i> ¹⁰	<i>PCI</i>	<i>Bruto vrijednost izvoza, u milijunima USD</i>	<i>Poduzeća izvoznici</i>
5	8113	<i>Kermet i predmeti od kermeta, uključujući otpatke i lomljevinu</i>	2,33	0,116	FTS d.o.o. (malo)
7	3707	<i>Kemijski pripravci za fotografsku uporabu (osim lakova, ljepila, sredstava za lijepljenje i sličnih</i>	2,26	1,01	RADIN-GRAFIKA d.o.o. (veliko)

		<i>pripravaka); nepomiješani proizvodi za fotografsku uporabu, pripremljeni u odmjerene doze ili pripremljeni u pakiranja za pojedinačnu prodaju u obliku gotovom za uporabu</i>			
9	9010	<i>Aparati i oprema za fotografske (uključujući kinematografske) laboratorije; negatoskopi; projekcijski zasloni</i>	2,23	0,595	nema podataka
10	3705	<i>Fotografske ploče i filmovi, osvijetljeni i razvijeni, osim kinematografskih filmova</i>	2,23	0,0321	nema podataka
11	8457	<i>Obradni centri, strojevi konstruirani od standardnih jedinica (s jednom stanicom) i transfer strojevi s više stanica, za obradu kovina</i>	2,22	3,95	P.P.C. Buzet d.o.o. (veliko) SAS Strojogradnja d.o.o. (srednje)
12	8209	<i>Pločice, štapići, vrhovi i slično za alate od kermeta</i>	2,1	2,55	FTS d.o.o. (malo) Alfa Tim d.o.o. (malo)
13	5502	<i>Strukovi od umjetnih filamenata</i>	2,06	0,00521	nema podataka
14	9022	<i>Rendgenski aparati i aparati na osnovi alfa-, beta- ili gama-zračenja, neovisno jesu li namijenjeni uporabi u medicini, kirurgiji, zubarstvu ili veterini ili ne, uključujući aparate za radiografiju ili radioterapiju, rendgenske cijevi i ostali</i>	2,05	2,51	IDEF d.o.o. za industrijsku defektoskopiju i trgovinu (malo)

		<i>generatori rendgenskih zraka, generatori visokog napona, upravljačke ploče i stolovi, zasloni te stolovi, stolice i slično, namijenjeni pregledu ili liječenju</i>			
16	9027	<i>Instrumenti i aparati za fizikalne ili kemijske analize (na primjer, polarimetri, refraktometri, spektrometri, aparati za analizu plina ili dima); instrumenti i aparati za mjerenje ili kontrolu viskoziteta, poroznosti, dilatacije, površinske napetosti ili slično; instrumenti i aparati mjerenje ili kontrolu toplinskih, zvučnih ili svjetlostnih veličina (uključujući svjetlomjere); mikrotomi</i>	2,01	6,55	IDEF d.o.o. za industrijsku defektoskopiju i trgovinu (malo)
18	8461	<i>Alatni strojevi za dugohodno blanjanje, kratkohodno blanjanje, dubljenje ili provlačenje, ozublјivanje, brušenje ili završnu obradu ozublјenja, piljenje, rezanje reznom pločom te ostali alatni strojevi za obradu kovina ili kermeta odvajanjem čestica, nespomenuti niti uključeni na drugom mjestu</i>	1,98	0,257	ISTRATEHNA d.o.o. (malo)
20	8487* *8485	<i>Dijelovi strojeva, aparata i uređaja bez električnih priključaka, izolatora, svitaka, kontakata ili drugih električnih obilježja, nespomenuti niti uključeni na drugom mjestu u ovom poglavlju</i>	1,88	14,2	AB Montaža d.o.o. (malo) TEH-CUT d.o.o. (malo) TINITA d.o.o. (malo)

4.3. Proizvodnja hrvatskih najsloženijih proizvoda

Istraživanje najsloženijih proizvoda prethodno opisanih u tablici 7. u makroekonomskom sustavu hrvatskog gospodarstva otežano je iz više objektivnih razloga. Prvi je nemogućnost dohvaćanja trgovinskih podataka na temelju kojih bi se identificirali najsloženiji proizvodi iz tekuće 2019. godine. Proizvodi u tablici 7. identificirani su na temelju recentnih dostupnih trgovinskih podataka iz 2016. godine. Drugi razlog je što istraživanjem postojećih izvora temeljem kojih bi se neposredno identificirali proizvođači u Hrvatskoj nije pronađen jedinstven i sveobuhvatan izvor takvih informacija. Međutim, oni izvori temeljem kojih je posredstvom pripadajućih im tražilica ili nezavisnih tražilica moguće identificirati proizvođače, nemaju mogućnost pretrage sukladno klasifikacijama HS i SMTK **proizvodnih skupina** koje oni proizvode, već sukladno Nacionalnoj klasifikaciji **djelatnosti** (NKD) kojima se oni bave. Stoga je istraživanje **izvoza RH** – temeljnog izvora trgovinskih podataka *Atlasa ekonomske složenosti*, uzeto kao temelj istraživanju same **proizvodnje**. Metodologija istraživanja obuhvaćala je pretragu Registra izvoznika Hrvatske gospodarske komore (HGK) tražilicom Google prema kôdovima HS-a. Sukladno dostupnosti javnih podataka za građanstvo kako Registra HGK, tako i službenih web stranica pojedinih tvrtki i Financijske agencije RH (FINA), opisane su tvrtke koje **izvoze**, odnosno tvrtke, tehnologije i strukture, lokacije i vlasništva poduzeća, odnosno pogona u kojima se **proizvode** proizvodi iz tablice 7. Valja istaknuti kako registrirani izvoz pojedinih proizvoda u većini slučajeva nije značio ujedno i njihovu proizvodnju u makroekonomskom sustavu hrvatskog gospodarstva.

Registrirani izvoznik pri Registru HGK najsloženije proizvodne skupine prisutne u hrvatskom gospodarstvu kôda HS4 8113: *kermeta i predmeta od kermeta* i proizvodne skupine kôda HS4 8209: *pločica, štapića, vrhova i sl. za alate od kermeta* (Tablica 7.) je trgovačko društvo s ograničenom odgovornošću koje posluje pod tvrtkom **FTS d.o.o. za zastupanje, trgovinu i projektiranje**. Tvrtka je osnovana 1993. u Zagrebu, u privatnom je vlasništvu i ima četiri zaposlene osobe, a podrijetlo kapitala je u cijelosti hrvatsko. Glavna djelatnost tvrtke prema NKD-u je **4690 – nespecijalizirana trgovina na veliko**. Tvrtka nema vlastiti proizvodni sustav, odnosno ne proizvodi proizvodne skupine od kermeta. Proizvođači reznog i prihvatnog alata od kermeta koje tvrtka zastupa uglavnom su inozemni: SECO, CeramTec, INOVATOOLS, DC SWISS DA, SIMTEC, BAHCO. [26 i 30]

4.3.1. RADIN-GRAFIKA d.o.o.

Registrirani izvoznik pri Registru HGK proizvodne skupine kôda HS4 3707: *kemijski pripravci za fotografsku uporabu (osim lakova, ljepila, sredstava za lijepljenje i sličnih pripravaka); nepomiješani proizvodi za fotografsku uporabu, pripremljeni u odmjerene doze ili pripremljeni u pakiranja za pojedinačnu prodaju u obliku gotovom za uporabu* (Tablica 7.) je trgovačko društvo s ograničenom odgovornošću koje posluje pod tvrtkom **RADIN-GRAFIKA d.o.o.** [26 i 31]

Tvrtka je osnovana 1996., u privatnom je vlasništvu i ima 72 zaposlene osobe, a podrijetlo kapitala je u cijelosti hrvatsko. Tvrtka posluje u Svetoj Nedelji (središnjica), Zagrebu, Rovinju, Osijeku i Splitu. Prema veličini spada u velika poduzeća, a glavna djelatnost tvrtke prema NKD-u je **4649 – trgovina na veliko ostalim proizvodima za kućanstvo**. Tvrtka se bavi **proizvodnjom** kemijskih sredstava, miješanjem grafičkih boja, proizvodnjom pomoćnih sredstava za tisak, rezanjem i prematanjem „jumbo rola“ i distribucijom industrijskih kemikalija i prirodnih sirovina. Zemlje u koje je tvrtka izvozi svoje proizvode su Slovenija, Srbija, Bosna i Hercegovina, Austrija, Italija, Makedonija, Nizozemska, Njemačka, Belgija (Slika 12.). [26 i 31]



Slika 12. Zemlje u koje tvrtka RADIN-GRAFIKA d.o.o. izvozi svoje proizvode [26]

Struktura tvrtke obuhvaća odjel prodaje papira i grafičkog repromaterijala, odjel prodaje digitalne opreme i materijala, odjel prodaje industrijskih kemikalija i prirodnih sirovina, odjel za ostale dijelove prodaje i odjel za kompenzacije. Među značajnim dobavljačima tvrtke

RADIN-GRAFIKA ističu se: AGFA, B&B, BURGO Group, Henkel, FUJIFIM Belgium NV, Gold East Paper i brojni drugi. [31]

4.3.2. P.P.C. Buzet d.o.o. i SAS Strojogradnja d.o.o.

Registrirani izvoznici pri Registru HGK proizvodne skupine kôda HS4 8457: *obradni centri, strojevi konstruirani od standardnih jedinica (s jednom stanicom) i transfer strojevi s više stanica, za obradu kovina* (Tablica 7.) su trgovačka društva s ograničenom odgovornošću koja posluju pod tvrtkama **P.P.C. Buzet d.o.o. i SAS Strojogradnja d.o.o.** [26]

P.P.C. Buzet je tvrtka je osnovana 1971. kada je na temelju poslovne suradnje s tvornicom Tomos iz Kopra u Buzetu izgrađen pogon s trima tehnološkim linijama za proizvodnju kotača, galvanika i montažu kotača. Nakon nekoliko godina uvedena je tehnološka linija proizvodnje automobilskih dijelova za francuski Citroën, a tvornica dobiva naziv CIMOS Buzet. [32]

CIMOS 2017. preuzima talijanska tvrtka TCH. P.P.C. Buzet danas ima proizvodne pogone u Buzetu, Roču i Labinu. Prema veličini poduzeća spada u velika poduzeća, a glavna djelatnost tvrtke prema NKD-u je **2932 – proizvodnja ostalih dijelova i pribora za motorna vozila**. Tvrtka zapošljava 568 ljudi. Među najznačajnijim proizvođačima automobila kojima P.P.C. Buzet isporučuje svoje proizvode izdvajaju se: BMW, Audi, Ford, Toyota i Opel. Proizvodi su namijenjeni prvoj ugradnji, a koncept koji se primjenjuje u proizvodnim sustavima je JIT (engl. *Just-in-Time*) prema dnevnim, tjednim i mjesečnim narudžbama kupaca. [26 i 33]

Glavne tehnologije koje se koriste u proizvodnim sustavima tvrtke uključuju: tlačno lijevanje aluminijske, gravitacijsko lijevanje aluminijske, niskotlačno lijevanje aluminijske, mehaničku obradu odvajanjem čestica, površinsku zaštitu (galvanizaciju i kataforetsko lakiranje), termičku obradu i montažu. Glavni proizvodni program sastoji se od: kućišta turbokompresora, nosača motora, pedalnih sklopova, kućišta uljnog filtera, kućišta pumpi za vodu, raznih osovinica za mjenjače i cijevi za ojačanje karoserije. Vidljivo je kako obradni centri, međutim, nisu dio **glavnog proizvodnog programa** tvrtke P.P.C. Buzet za razliku od SAS Strojogradnje d.o.o. čija je glavna djelatnost prema NKD-u **2849 – proizvodnja ostalih alatnih strojeva**. [26 i 33]

SAS Strojogradnja potječe od tvornice specijalnih alatnih strojeva SAS Zadar, a koja se pak razvila iz tvornice šivaćih strojeva osnovane 1961. Do 1990. poduzeće je dobro poslovalo i

naglo se razvijalo. Sama tvrtka SAS Strojogradnja d.o.o. osnovana je 1999. godine, a danas je vlasništvo tvrtke u cijelosti inozemno (vlasnik je javno poduzeće Ist International Sastrade Aktiengesellschaft iz Kneževine Lihtenštajn), a podrijetlo kapitala je 60 % hrvatsko i 40 % slovensko. [26 i 35]

Proizvodni program poduzeća uključuje specijalne alatne strojeve, obradbene centre, fleksibilne proizvodne sustave i linije i transportnu opremu. Područja primjene su visoka serijska proizvodnja u automobilskoj industriji, precizna mehanika, kućanski aparati, poljoprivredni strojevi i zrakoplovna industrija. Poduzeće svoje proizvode izvozi u Rusiju, Bjelorusiju, i većinu zemalja članica EU (Slika 13.). [26 i 35]




Slika 13. Zemlje u koje tvrtka SAS Strojogradnja d.o.o. izvozi svoje proizvode [26]

Dakle, na temelju dvadeset najsloženijih proizvoda prema indeksu složenosti proizvoda u hrvatskom gospodarstvu u 2016., u Registru HGK identificirano je deset tvrtki koje izvoze te proizvode. Od tih deset samo tvrtke RADIN-GRAFIKA d.o.o., P.P.C. Buzet d.o.o. i SAS Strojogradnja d.o.o. imaju vlastitu proizvodnju. Od toga, samo RADIN-GRAFIKA d.o.o. i SAS Strojogradnja d.o.o. proizvode skupine proizvoda iz tablice 7. u sklopu njihova (vlastitog) **glavnog proizvodnog programa**, a od njih je samo **RADIN-GRAFIKA d.o.o. u cijelosti u privatnom hrvatskom vlasništvu, a podrijetlo njena kapitala u cijelosti hrvatsko.**

5. MJERE POVEĆANJA INDEKSA EKONOMSKE SLOŽENOSTI RH

Grafikoni izvodljivosti (engl. *Feasibility Charts*) predstavljaju uz prostor proizvoda, alat za vizualizaciju složenosti, a čiji je rezultat vrsta grafikona raspršenja koji prikazuje različite mogućnosti diverzifikacije¹² proizvodnog programa gospodarstva neke zemlje na temelju onoga što ona trenutačno izvozi (Slika 14.). Jednostavnim rječnikom, grafikoni odgovaraju na pitanje: *Što je potrebno proizvoditi?* [15 i 19]




Slika 14. Grafikon izvodljivosti za gospodarstvo RH u 2016. [15]

Proizvodi posljednji po redoslijedu, krećući se lijevo po grafikonu iznad isprekidane linije, jesu proizvodi visokog potencijala ili proizvodi najpogodniji za diverzifikaciju postojećeg

¹² Prema Hrvatskoj enciklopediji Leksikografskog zavoda Miroslav Krleža **diversifikacija** označava proširenje gospodarske djelatnosti na veći broj proizvoda ili usluga, odnosno proširenje asortimana proizvodnje ili prodaje proizvoda. Velika poduzeća ili države nastoje proizvoditi raznovrsne proizvode, što im osigurava bolje pretpostavke za širenje proizvodnje i ravnomjerniji i stabilniji razvoj.


izvoznog programa. Određeni su na temelju sličnosti postojećeg znanja i iskustva (*know-how*) alociranog unutar prostora proizvoda (populacije). Pod tim se razumijeva praktično znanje i iskustvo, uključujući tvorničke tajne i postupke, konstrukcije, formule, recepte, pa i sitne radne upute, bez obzira na to jesu li pismeno utvrđene u obliku tehničke dokumentacije ili su samo usmeno prenesene. Spomenuti proizvodi imaju veću složenost od prosječne složenosti proizvodnog programa gospodarstva koje se razmatra te stoga izravno pridonose bržem rastu gospodarstva. Konačno, budući da su usko povezani s drugim proizvodima veće složenosti u prostoru proizvoda (koji se zbog postojećeg znanja i iskustva ne mogu proizvesti), proizvodnja proizvoda visokog potencijala „otvara“ još veće mogućnosti diverzifikacije. [15 i 19]

Prema grafikonu izvodljivosti za hrvatsko gospodarstvo iz 2016. dohvaćenom na službenim mrežnim stranicama *Atlasa*, u ovom će se radu posebno razmatrati proizvodne skupine najstroženijih proizvoda s obzirom na indeks složenosti proizvoda (PCI), a to su **strojevi, kemikalije, vozila i elektronika**. U proizvodnoj skupini strojeva kako je prikazano na slici 9., ističu se proizvodne skupine: **centrifuge, strojevi za dizanje, rukovanje, utovar ili istovar kao što su dizala, pokretne stube i slično, te strojevi za industrijsku pripremu ili proizvodnju hrane ili pića** (Slika 15. i Tablica 8.). [15]




Slika 15. Grafikon izvodljivosti za proizvodnu skupinu *strojevi* prema prostoru proizvoda RH u 2016. [15]

U proizvodnoj skupini kemikalija ističe se proizvodna skupina: **ionski izmjenjivači na osnovi polimera** (Slika 16. i Tablica 8.). [15]




Slika 16. Grafikon izvodljivosti za proizvodnu skupinu kemikalije prema prostoru proizvoda RH u 2016. [15]

U proizvodnoj skupini vozila ističe se proizvodna skupina: **dijelovi i pribor motornih vozila i osobnih automobila konstruiranih prvenstveno za prijevoz osoba uključujući motorna vozila tipa "karavan", "kombi" i trkaće automobile** (Slika 17. i Tablica 8.). [15]



Slika 17. Grafikon izvodljivosti za proizvodnu skupinu vozila prema prostoru proizvoda RH u 2016. [15]

U proizvodnoj skupini elektronika ističe se proizvodna skupina: **dijelovi prikladni za uporabu isključivo ili uglavnom s aparatima poput električnih aparata za uklapanje, isklapanje ili zaštitu električnih strujnih krugova ili za spajanje na ili u električnim strujnim krugovima** (Slika 18. i Tablica 8.). [15]



Slika 18. Grafikon izvodljivosti za proizvodnu skupinu *elektronika* prema prostoru proizvoda RH u 2016. [15]

Tablica 8., zaključno, sadrži pune nazive proizvoda unutar pojedinih proizvodnih skupina, njihov kôd HS4 i indeks složenosti proizvoda (PCI), a koji su prema grafikonu izvodljivosti, odnosno metodologiji alatā unutar *Atlasa ekonomske složenosti*, najpogodniji za diverzifikaciju i ubrzanje rasta hrvatskog gospodarstva. [15]

Tablica 8. Proizvodi najpogodniji za diverzifikaciju i ubrzanje rasta hrvatskog gospodarstva – Što je potrebno proizvoditi? [15]

<i>Kôd HS4</i>	<i>Proizvod¹⁰</i>
8421	<i>Centrifuge, uključujući centrifuge za sušenje; uređaji i aparati za filtriranje ili pročišćavanje, za tekućine ili plinove</i>
8428	<i>Strojevi za dizanje, rukovanje, utovar ili istovar (na primjer, dizala, pokretne stube, transporter, žičare)</i>
8438	<i>Strojevi za industrijsku pripremu ili proizvodnju hrane ili pića, osim strojeva za ekstrakciju ili pripremu životinjskih ili nehlapivih (masnih) biljnih masti ili ulja</i>
3914	<i>Ionski izmjenjivači na osnovi polimera</i>
8708	<i>Dijelovi i pribor motornih vozila iz tarifnih brojeva 8701 do 8705^a ^aVučna vozila, motorna vozila za prijevoz deset ili više osoba, osobni automobili i ostala motorna vozila konstruirana prvenstveno za prijevoz osoba, motorna vozila za prijevoz robe.</i>
8703	<i>Osobni automobili i ostala motorna vozila konstruirana prvenstveno za prijevoz osoba uključujući motorna vozila tipa "karavan", "kombi" i trkaće automobile</i>
8538	<i>Dijelovi prikladni za uporabu isključivo ili uglavnom s aparatima iz tarifnog broja 8535, 8536 ili 8537^b ^bElektrični aparati za uklapanje, isklapanje ili zaštitu električnih strujnih krugova ili za spajanje na ili u električnim strujnim krugovima te ploče, pultovi, stolovi, ormari i ostali nosači.</i>

6. MOGUĆNOST PRIMJENE INDEKSA EKONOMSKE SLOŽENOSTI ZA PROJEKTIRANJE PROIZVODNIH SUSTAVA


6.1. Hipoteza

Premda je indeks ekonomske složenosti razvijan za veće ekonomske sustave (države ili regije), nameće se ideja istražiti njegovu primjenu u projektiranju proizvodnih sustava, kako u ranim (konceptualnim) fazama razvoja (projektiranja) proizvodnog sustava, tako i za praćenje njegova rada.¹³

Model moguće primjene indeksa ekonomske složenosti, odnosno indeksa složenosti proizvoda temelji se na **metodi refleksije**. Metodom refleksije iterativnim se postupcima (refleksijama) nastoji doći do rješenja graničnih vrijednosti linearnih problema u sustavima više povezanih domena. Metodu je prvi primijenio poljski fizičar Marian von Smoluchowski 1911. godine. Sličnu ideju koristio je i ruski matematičar Genadij Mihailovič Goluzin 30-ih godina 20. stoljeća. Godine 2016. Philippe Laurent, Guillaume Legendre i Julien Salomon objavili su rad u kojem su dokazali njenu konvergenciju. Međutim, sama metoda još je uvijek predmetom dodatnih istraživanja, posebice u području numeričke analize. [37 i 38]

Hidalgo i Hausmann u svojem *Atlasu* za primjer opisuju jednostavan model koji sadrži mrežu povezanih zemalja i proizvoda. [19] Stoga bi hipoteza modela primjene indeksa za projektiranje proizvodnih sustava glasila: **kada bi se umjesto zemalja koristile tvrtke, odnosno pojedinačni proizvodni sustavi, metodom refleksije mogla bi se analizirati struktura pojedinih proizvodnih sustava i pripadajuća im sofisticiranost na temelju proizvoda koje proizvode** (Slika 19.).

¹³ Naprimjer poredbeno, važnost razmatranja tehnološkičnosti proizvoda u ranim (konceptualnim) fazama razvoja istaknuli su i dokazali svojom metodom DFMA Boothroyd i Dewhurst 1980. godine.



Slika 19. Mreža proizvodnih sustava (S) i proizvoda (P)

6.2. Model

Broj različitih proizvoda (ili stupanj diverzifikacije) unutar proizvodnog sustava (Slika 19.) može se definirati koeficijentima, odnosno izrazima (11) do (14):

$$k_{S1,0}=4 \quad (11)$$

$$k_{S2,0}=1 \quad (12)$$

$$k_{S3,0}=2 \quad (13)$$

$$k_{S4,0}=1 \quad (14)$$

Svenazočnost, odnosno ubikvitet proizvoda može se definirati koeficijentima, odnosno izrazima (15) do (18):

$$k_{P1,0}=1 \quad (15)$$

$$k_{P2,0}=2 \quad (16)$$

$$k_{P3,0}=2 \quad (17)$$

$$k_{P4,0}=3 \quad (18)$$

Slijedi izračun metodom refleksije. Prva refleksija (iteracija) sastoji se od prosječne svenazočnosti ili ubikviteta proizvoda unutar različitih proizvodnih sustava ($k_{Sn,1}$) i prosječne diverzifikacije pojedinih proizvodnih sustava ($k_{Pn,1}$) i dana je izrazima (19) do (26):

$$k_{S1,1} = \frac{1}{4} \cdot (1 + 2 + 2 + 3) = 2 \quad (19)$$

$$k_{S2,1} = \frac{1}{1} \cdot (2) = 2 \quad (20)$$

$$k_{S3,1} = \frac{1}{2} \cdot (2 + 3) = 2,5 \quad (21)$$

$$k_{S4,1} = \frac{1}{1} \cdot (3) = 3 \quad (22)$$

$$k_{P1,1} = \frac{1}{1} \cdot (4) = 4 \quad (23)$$

$$k_{P2,1} = \frac{1}{2} \cdot (4 + 1) = 2,5 \quad (24)$$

$$k_{P3,1} = \frac{1}{2} \cdot (4 + 2) = 3 \quad (25)$$

$$k_{P4,1} = \frac{1}{3} \cdot (4 + 2 + 1) = 2,33 \quad (26)$$

Druga refleksija izračunava se prosječnim vrijednostima susjednih čvorova prve refleksije i dana je izrazima (27) do (34):

$$k_{S1,2} = \frac{1}{4} \cdot (4 + 2,5 + 2,25 + 2,5) = 2,9583 \quad (27)$$

$$k_{S2,2} = \frac{1}{1} \cdot (2,5) = 2,5 \quad (28)$$

$$k_{S3,2} = \frac{1}{2} \cdot (3 + 2,333) = 2,66 \quad (29)$$

$$k_{S4,2} = \frac{1}{1} \cdot (2,33) = 2,33 \quad (30)$$

$$k_{P1,2} = \frac{1}{1} \cdot (2) = 2 \quad (31)$$

$$k_{P2,2} = \frac{1}{2} \cdot (2 + 2) = 2 \quad (32)$$

$$k_{P3,2} = \frac{1}{2} \cdot (2 + 2,5) = 2,25 \quad (33)$$

$$k_{P4,2} = \frac{1}{3} \cdot (2 + 2,5 + 3) = 2,5 \quad (34)$$

Hidalgo i Hausmann u *Atlasu* na sličnom primjeru dokazuju konvergenciju metode refleksije, odnosno sposobnost razlikovanja različitih zemalja kroz refleksije (iteracije), a na temelju informacija o proizvodima koje te zemlje izvoze. [19]

Nastavak izračuna refleksijama (iteracijama) dovodi do zaključka da postoji informacija „skrivena“ u relativnom položaju proizvodnih sustava i proizvoda međusobno. Primjerice, razmatrajući vrijednosti koeficijenata proizvodnih sustava nakon druge refleksije ($k_{S,2}$) uočljivo je da sustav S1 ima najveću vrijednost ($k_{S1,2}=2,9583$) u izrazu (27), a slijede sustavi S3 ($k_{S3,2} = 2,66$), S2 ($k_{S2,2} = 2,5$), S4 ($k_{S4,2} = 2,33$).

Iako oba sustava proizvode po jedan proizvod, u drugoj refleksiji proizvodni sustav S2 ima veći koeficijent od sustava S4. Razlog leži u činjenici što druga refleksija uzima u obzir „skrivenu“ informaciju o proizvodnom sustavu S2 koji proizvodi proizvod koji se nalazi samo u visoko diverzificiranim proizvodnim sustavima (u ovom primjeru je to sustav S1). Ta „skrivena informacija“ znači da proizvodni sustav S2 ima bolji položaj od sustava S4 jer iako proizvodi mali broj proizvoda, to jest samo proizvod P2, taj proizvod nije svenazočan. Jednostavnijim rječnikom rečeno, ne mogu ga svi proizvodni sustavi proizvesti.

Naprotiv, sustav S4 proizvodi P4 koji je svenazočan (S1, S3, S4) što ukazuje na to da je riječ o jednostavnom proizvodu koji može proizvoditi gotovo svaki proizvodni sustav. Dakle, iako oba sustava S2 i S4 proizvode isti broj proizvoda (po jedan), metoda ih može razlikovati i konvergirati sustavu S2 kao sustavu složenije proizvodne strukture od one u sustavu S4.

Model daje informaciju o nazočnosti proizvoda unutar skupine različitih proizvodnih sustava i primjenjiv je pri analizi proizvodnih mreža i pronalaženju strateških partnera ili pronalaženju kooperanata. Model ne daje odgovor na pitanje koliko je koji proizvod vrijedan na globalnoj razini (koliko ga je teško proizvesti). Stoga, pri detaljnijoj analizi proizvodnih sustava potrebno je uvrstiti i dodatne faktore vezane za kompleksnost samih proizvoda (PCI) koje neki proizvodni sustav proizvodi.

6.3. Proširenje osnovnog modela primjenom indeksa složenosti

Uvrštavanjem u već postojeći model koeficijenti proizvoda koji označavaju njihove količine množe se vrijednostima indeksa složenosti proizvoda (PCI). Postavlja se pitanje konvergira li tada metoda refleksije brže za pojedine proizvodne sustave (S1 do S4). U proširenju modela uvrštavanjem PCI vrijednosti cilj je bio dobiti sustav koji će proizvodnji, odnosno

gospodarstvu najviše pridonositi razvoju i rastu, s obzirom da analogno metodologiji indeksa ekonomske složenosti, proizvodi najvećeg indeksa složenosti najviše pridonose rastu i razvoju makroekonomskog sustava.

Broj različitih proizvoda (ili stupanj diverzifikacije) i pripadajućih im složenosti (PCI) koji se proizvode može se definirati izrazom (35):

$$k_{Sn,0} = \sum_1^n P_n \cdot \alpha_n \quad (35)$$

gdje je α_n = PCI vrijednost za 2017. godinu prema OEC-ovim listama i to za prvi proizvod $\alpha_1 = -0,951$, za drugi $\alpha_2 = 1,642$, za treći $\alpha_3 = 0,792$ i za četvrti $\alpha_4 = 1,178$. [37]

Slijedi izračun koeficijenata dan izrazima (36) do (39):

$$k_{S1,0} = (1 \cdot -0,951) + (1 \cdot 1,642) + (1 \cdot 0,792) + (1 \cdot 1,178) = 2,661 \quad (36)$$

$$k_{S2,0} = (1 \cdot 1,642) = 1,642 \quad (37)$$

$$k_{S3,0} = (1 \cdot 0,792) + (1 \cdot 1,178) = 1,97 \quad (38)$$

$$k_{S4,0} = (1 \cdot 1,178) = 1,178 . \quad (39)$$

Svenazočnost, odnosno ubikvitet proizvoda može se definirati koeficijentima danim izrazima (15) do (18). [19]

Slijedi izračun prve refleksije koji se sastoji od prosječne svenazočnosti ili ubikviteta proizvoda unutar različitih proizvodnih sustava ($k_{Sn,1}$) i prosječne diverzifikacije pojedinih proizvodnih sustava ($k_{Pn,1}$) dan izrazima (40) do (47), kako slijedi:

$$k_{S1,1} = \frac{1}{2,661} \cdot (1 + 2 + 2 + 3) = 3,00639 \quad (40)$$

$$k_{S2,1} = \frac{1}{1,642} \cdot (2) = 1,21802 \quad (41)$$

$$k_{S3,1} = \frac{1}{1,97} \cdot (2 + 3) = 2,53807 \quad (42)$$

$$k_{S4,1} = \frac{1}{1,178} \cdot (3) = 2,54669 \quad (43)$$

$$k_{P1,1} = \frac{2,661}{1} \cdot (4) = 10,644 \quad (44)$$

$$k_{P2,1} = \frac{1,642}{2} \cdot (4 + 1) = 4,105 \quad (45)$$

$$k_{P3,1} = \frac{1,97}{2} \cdot (4 + 2) = 5,91 \quad (46)$$

$$k_{P4,1} = \frac{1,178}{3} \cdot (4 + 2 + 1) = 2,74867 . \quad (47)$$

Druga refleksija izračunava se prosječnim vrijednostima susjednih čvorova prve refleksije i dana je izrazima (48) do (51):

$$k_{S1,2} = \frac{1}{4} \cdot (10,644 + 4,105 + 5,91 + 2,74867) = 5,85192 \quad (48)$$

$$k_{S2,2} = \frac{1}{1} \cdot (4,105) = 4,105 \quad (49)$$

$$k_{S3,2} = \frac{1}{2} \cdot (5,91 + 2,74867) = 4,32934 \quad (50)$$

$$k_{S4,2} = \frac{1}{1} \cdot (2,74867) = 2,74867. \quad (51)$$

Uočljivo je kako metoda konvergira sukladno složenosti proizvoda prema sustavu **S1**, dok prema indeksu složenosti proizvoda sustav **S4** ima najmanji ukupan koeficijent i najmanje pridonosi rastu i razvoju proizvodnje, odnosno gospodarstva. **Stoga je izgledno da se ovaj model može primijeniti u projektiranju proizvodnih sustava (odnosno identifikaciji perspektivnih proizvoda i izboru reprezentantnih proizvoda).**

Sintezom dostupnih trgovinskih podataka, odnosno podataka o složenosti proizvoda, moguće je metodom refleksije izraziti one proizvode čijom bi proizvodnjom neki proizvodni sustav generirao najveći koeficijent složenosti, a time i pridonosio rastu i razvoju same proizvodnje, odnosno gospodarstva. Danjim razvojem modela, otvara se mogućnost primjene metodologije izračuna (metode refleksije) indeksa ekonomske složenosti, odnosno indeksa složenosti proizvoda u manjim ekonomskim, odnosno proizvodnim sustavima.

6.3.1. Preporučene tehnologije za razvoj i primjenu proširenog modela

Daljnji razvoj modela, a s obzirom na količinu trgovinskih podataka koji se mogu dohvatiti iz relevantnih svjetskih baza podataka, zahtijeva primjenu informatičkih tehnologija sposobnih obraditi velike količine podataka. U razmatranju posebnih tehnologija otkrivanja *znanja* ili *informacija* u velikim količinama podataka, ističe se dubinska analiza podataka (engl. *Data Mining*) ili tzv. *rudarenje podataka* koje se temelji na statističkim metodama, postupcima (algoritmima) strojnog učenja (engl. *Machine Learning*), vizualizacije podataka, te bazama podataka. [38]

Osim postojećih modela rudarenja podataka temeljenih na različitim predviđajućim (prediktivnim) i opisnim (deskriptivnim) matematičkim metodama rudarenja, moguće je unutar softvera koji „rudari“ podatke primijeniti metodu refleksije. Na taj način otvara se

moгуćnost obrade, odnosno analize i sinteze velikih količina trgovinskih podataka, podataka o proizvodnim sustavima i podataka o složenosti proizvoda (PCI) u cilju otkrivanja „skrivenog znanja“ o strukturama proizvodnih sustava na temelju proizvoda koje proizvode. Konkretna softver, odnosno tehnologija rezultirala bi preciznim, matematički utemeljenim zaključcima o onim proizvodnim sustavima koji najviše pridonose rastu i razvoju pojedinog gospodarstvenog sustava.

Izvjerno je da proizvodni sustavi koji imaju tehnologiju i znanje za proizvodnju proizvoda visokog tehnološkog značaja imaju određenu konkurentsku prednost i bolju poziciju na tržištu, a samim time i veće šanse za opstojnost i rast. Tehnološka razina i znanje donekle je utkana unutar PCI indeksa, no s ciljem detaljnije analize potrebno je u model (na stranu proizvoda) uvrstiti i druge faktore vezane za maksimalne količine i stupanj automatizacije. [39]

U detaljnoj analizi valjalo bi analizirati i sam proizvodni sustav s ekonomskih, društvenih i drugih stajališta uvođenjem faktora vezanih za njegovu „opstojnost“. Faktori vezani za proizvodni sustav tako mogu biti broj patenata, ekonomska analiza, nesigurnost tržišta, mogućnost dobave sirovina, pronalaženja strateškog partnera i kvalitetne radne snage i drugo. [38 do 40]

Predloženi model s uvedenim svrsishodnim faktorima na strani poduzeća i proizvoda dao bi kvalitetnu sliku o sadašnjem stanju na tržištu te vjerojatnosti opstojnosti i rasta poduzeća u budućnosti. Metoda bi mogla biti kvalitetna podloga u odlučivanju o investicijama, proširenju ali i potencijalnom ukidanju proizvodnih sustava (ali i gospodarskih u slučaju da se primjeni na višu razinu). [40 i 41]

7. ZAKLJUČAK

U ovom je radu pomoću holističkih mjera gospodarstvenog rasta makroekonomskih sustava – indeksa ekonomske složenosti i indeksa složenosti proizvoda, dana analiza makroekonomskog sustava gospodarstva Republike Hrvatske. Istražena je dostupna i relevantna znanstvena literatura temeljem koje je opisano sadašnje stanje hrvatskog gospodarstva. Uočeno je kako se ključna pitanja hrvatskog gospodarstva vezuju prvenstveno za pojam *oporavka*, a zatim ubrzavanja *rasta*. Na temelju opisane metodologije izračuna indeksa ekonomske složenosti, pomoću alatā *Atlasa ekonomske složenosti*, izrađena je dubinska analiza hrvatskog gospodarstva. Analizom su identificirani najsloženiji proizvodi u hrvatskom gospodarstvu kao i tvrtke koje ih izvoze, odnosno proizvode. Uočen je nedostatak metodologije indeksā koja izvoz određenog proizvoda poistovjećuje s njegovom proizvodnjom, odnosno tvrtke koje su registrirani izvoznici određenog proizvoda nisu uvijek ujedno i njegovi proizvođači.

Predložene su mjere povećanja indeksa ekonomske složenosti gospodarstva RH na temelju grafikona izvodljivosti, a posebno su **istaknute proizvodne skupine koje Hrvatska treba proizvoditi** kako bi ostvarila najveći i najbrži rast gospodarstva (Tablica 8.): strojevi, kemikalije, vozila i elektronika.

U radu je nadalje opisan model na primjeru Hidalgo i Hausmanna, a za izračun složenosti proizvodne strukture pojedinog proizvodnog sustava, odnosno njegove diverzifikacije metodom refleksije. Model je proširen uvrštavanjem indeksa složenosti proizvoda (PCI) u izračun refleksijā (iteracijā) te je dobiven zaključak o konvergenciji metode za onaj sustav čija kombinacija proizvoda koji se u njemu proizvode sukladno njihovom indeksu složenosti proizvoda, odnosno nazočnosti ili ubikviteta unutar drugih proizvodnih sustava, generira najveću ukupnu složenost, a samim time i doprinos rastu i razvoju proizvodnje (odnosno u konačnici gospodarstva). Razvojem modela otvorena je mogućnost **povezivanja indeksa složenosti malih ekonomskih, odnosno proizvodnih sustava sa makroekonomskim, odnosno ukazana moguća izravna veza složenosti proizvodnje i rasta i razvoja gospodarstva.**

Za nastavak razvoja i primjenu modela na proizvodne sustave, predlaže se tehnologija rudarenja podataka kojom bi se iz velikih količina podataka o trgovini, proizvodima i proizvodnim sustavima iz svjetskih baza trgovinskih podataka, baza podataka pojedinih proizvodnih sustava i temeljem podataka o proizvodima, izvodili precizni, matematički utemeljeni zaključci **o onim proizvodnim sustavima koji najviše pridonose rastu i razvoju pojedinog gospodarstvenog sustava.**

8. LITERATURA

- [1] Classical Numismatic Group Research Coins: Electronic Auction 370, 622., <https://www.cngcoins.com/Coin.aspx?CoinID=306742>, pristupljeno: 18. ožujka 2019.
- [2] Slukan Altić, M.: *Hrvatska u europskim regionalizacijama: regionalizacija kao integracija ili geografija moći*, Društvena istraživanja: časopis za opća društvena pitanja 17 (2008.) 3, str. 351.-372.
- [3] Perkov, J., Mikulandra Volić, I., Lastavec, M.: *Revidiranje makroekonomskih pokazatelja u EU-28 na primjeru bruto nacionalnog dohotka*, Oeconomica Jadertina 27 (2017.) 1, str. 41.-53.
- [4] Europska komisija: *Which Member States Have the Largest Share of EU's GDP?*, <https://ec.europa.eu/eurostat/web/products-eurostat-news/-/DDN-20180511-1?inheritRedirect=true>, pristupljeno: 4. studenoga 2018.
- [5] Tomić-Koludrović, I., Petrić, M.: *Hrvatsko društvo – prije i tijekom tranzicije*, Društvena istraživanja: časopis za opća društvena pitanja, 16 (2007.) 4-5, str. 867.-889.
- [6] Perković, M., Puljiz, V.: *Ratne štete, izdaci za branitelje, žrtve i stradalnike rata u Republici Hrvatskoj*, Revija za socijalnu politiku 8 (2001.) 2, str. 235.-238.
- [7] Gregurek, M.: *Stupanj i učinci privatizacije u Hrvatskoj*, Ekonomski pregled 52 (2001.) 1-2, str. 155.-188.
- [8] Hrvatska narodna banka: *Glavni makroekonomski indikatori*, <https://www.hnb.hr/statistika/glavni-makroekonomski-indikatori>, pristupljeno: 15. studenoga 2018.
- [9] Marić, K., Matić, J.: *Inozemna izravna ulaganja u Republiku Hrvatsku i usporedba s odabranim nerazvijenim zemljama*, Zbornik sveučilišta Libertas 3 (2018.), str. 147.-167.
- [10] Mlikotić, S.: *Globalna financijska kriza – uzroci, tijek i posljedice*, Pravnik: časopis za pravna i društvena pitanja 44 (2010.) 89, str. 83.-94.
- [11] Europska komisija: *Strategija Europa 2020.*, https://ec.europa.eu/info/business-economy-euro/economic-and-fiscal-policy-coordination/eu-economic-governance-monitoring-prevention-correction/european-semester/framework/europe-2020-strategy_hr, pristupljeno: 20. studenoga 2018.
- [12] Industrijska strategija Republike Hrvatske, Narodne novine, br. 126/14

- [13] Europska komisija (2006.), *Statistika robne razmjene – Priručnik za korisnike*, Europska komisija, Luksemburg
- [14] *Strategija pametne specijalizacije Republike Hrvatske za razdoblje od 2016. do 2020. godine i akcijski plan za provedbu Strategije pametne specijalizacije Republike Hrvatske za razdoblje od 2016. do 2017. godine*, Narodne novine, br. 32/16
- [15] Atlas of Economic Complexity: *What Did Croatia Export in 2016?*, <http://atlas.cid.harvard.edu/explore/?country=100&partner=undefined&product=undefined&productClass=HS&startYear=undefined&target=Product&year=2016>, pristupljeno: 3. siječnja 2019.
- [16] Bongaarts, J.: *Human Population Growth and the Demographic Transition*, Philosophical Transactions of the Royal Society B: Biological Sciences 27 (2009.) 364, str. 2985.-2990.
- [17] Chromjakova F.: *Flexible man-man motivation performance management system for Industry 4.0*, International Journal of Management Excellence 7 (2016.), str. 829.-840.
- [18] Družić, G., Basarac Sertić, M.: *Hrvatska i četvrta industrijska revolucija*, Hrvatska akademija znanosti i umjetnosti, Zagreb: Ekonomski fakultet, 2018., str. 283.-308.
- [19] Hausmann, R., Hidalgo, C. A., Bustos, S. i sur.: *The Atlas of Economic Complexity: Mapping Paths to Prosperity*, Boston, Massachusetts: Center for Institutional Development, Harvard University, MIT Media Lab, 2011.
- [20] Worldwide Governance Indicators, <http://info.worldbank.org/governance/wgi/#reports>, pristupljeno: 20. ožujka 2019.
- [21] Our World in Data: *Economic Complexity Index by Country Ranking 2016*, <https://ourworldindata.org/grapher/economic-complexity-index-eci-by-country-ranking?tab=map&time=1964..228016>, pristupljeno 29. svibnja 2019.
- [22] Observatory for Economic Complexity: *Economic Complexity Rankings*, <https://atlas.media.mit.edu/en/rankings/country/eci/>, pristupljeno: 29. svibnja 2019.
- [23] Center for International Development at Harvard University: *The Atlas of Economic Complexity*, <http://atlas.cid.harvard.edu/>, pristupljeno: 3. siječnja 2019.
- [24] United Nations International Trade Statistics Knowledgebase: *Harmonized Commodity Description and Coding Systems (HS)*, <https://unstats.un.org/unsd/tradekb/Knowledgebase/50018/Harmonized-Commodity-Description-and-Coding-Systems-HS>, pristupljeno 2. travnja 2019.
- [25] ITMS sustav Carinske Uprave Republike Hrvatske, <https://taric.carina.hr/index.do>, pristupljeno 29. svibnja 2019.

- [26] Hrvatska gospodarska komora: *Registar hrvatskih izvoznika*, <http://izvoznici.hgk.hr/>, pristupljeno 3. travnja 2019.
- [27] Pasche, M.: *Product Complexity Reduction – Not Only a Strategy Issue*, 11th Quality Management and Organizational Development Conference: Attaining Sustainability From Organizational Excellence to Sustainable, 20.-22. kolovoza 2008., Helsingborg, Švedska, str. 955
- [28] Observatory for Economic Complexity: *Economic Complexity Rankings*, https://atlas.media.mit.edu/en/rankings/product/hs07/?year_range=2013-2017, pristupljeno: 29. svibnja 2019.
- [29] Atlas of Economic Complexity: *Product Complexity Rankings*, <http://atlas.cid.harvard.edu/rankings/product/>, pristupljeno: 3. siječnja 2019.
- [30] FTS d.o.o. za zastupanje, trgovinu i projektiranje, <http://www.fts.hr/index.php/hr/>, pristupljeno 24. lipnja 2019.
- [31] RADIN-GRAFIKA d.o.o., https://www.radin-grafika.hr/hrvatski/naslovnica_1/, pristupljeno 24. lipnja 2019.
- [32] Istrapedia: *P.P.C. Buzet*, <https://www.istrapedia.hr/hrv/3220/p-p-c-buzet/istra-a-z/>, pristupljeno 24. lipnja 2019.
- [33] AD Klaster: *Cimos-P.P.C. Buzet*, <http://adklaster.hr/hr/members/ppcbuzet>, pristupljeno 24. lipnja 2019.
- [34] SAS Strojogradnja d.o.o., <https://sas-strojogradnja.hr/>, pristupljeno 24. lipnja 2019.
- [35] Leksikografski zavod Miroslav Krleža: Hrvatska tehnička enciklopedija: *SAS Zadar*, <http://tehnika.lzmk.hr/sas-zadar/>, pristupljeno 24. lipnja 2019.
- [36] Laurent, P., Legendre, G., Salomon, P.: *On the Method of Reflections*, https://hal.archives-ouvertes.fr/hal-01439871/file/lhs_final_hal_v1_2.pdf, pristupljeno 24. lipnja 2019.
- [37] Observatory for Economic Complexity: *Product Complexity Rankings*, https://atlas.media.mit.edu/en/rankings/product/hs07/?year_range=2013-2017, pristupljeno: 25. lipnja 2019.
- [38] Jacobs, M.: *Complexity: Toward an Empirical Measure*, Technovation 33 (2013.), str. 111.-118.
- [39] Belić, D.: *Model za izbor lokacije i veličine proizvodnog sustava primjenom metoda višekriterijskog odlučivanja*, Rukopis doktorske disertacije, Zagreb, 2019.

- [40] Orfi, N., Terpenney, J., Sahin-Sariisik, A.: *Harnessing Product Complexity: Step 2—Measuring and Evaluating Complexity Levels*, The Engineering Economist: A Journal Devoted to the Problems of Capital Investment 57 (2012.) 3, str. 178.-191.
- [41] Budde, L., Nagler, O., Friedli, T.: *A Method to Set Up a Complexity Index to Improve Decision-making Performance*, Procedia CIRP 36 (2015.), str. 53.-58.